

Risto Monnonen

# **VARASTONIMIKKEIDEN KYSYNNÄN ENNUSTAMINEN HANKINNAN TUKENA PROJEKTILIIKETOIMINNASSA**

Diplomityö  
Tekniikan ja luonnontieteiden tiedekunta  
Tarkastaja: Jussi Heikkilä  
Tarkastaja: Aki Jääskeläinen  
Marraskuu 2019

# TIIVISTELMÄ

Risto Monnonen: Varastonimikkeiden kysynnän ennustaminen hankinnan tukena projektiliiketoiminnassa  
Diplomityö, 98 sivua  
Tampereen yliopisto  
Tuotantotalouden diplomi-insinöörin tutkinto-ohjelma  
Marraskuu 2019

---

Yritykset pystyvät parantamaan kilpailuetuaan varautumalla tulevaisuuteen. Jotta tulevaisuuteen pystyttäisiin varautumaan, on tulevaisuuden tilasta ja muutoksista tehtävä arvioita. Näiden arvioiden ja ennusteiden pohjalta pystytään tekemään suunnitelmia, jotka pyrkivät vastaamaan tuleviin muutoksiin nykyhetkestä. Ennustaminen varastohallinnan ja hankinnan kannalta voidaan nähdä keskeiseksi toiminnoksi sujuvan tuotannon varmistamiseksi. Projektiliiketoiminnassa sujuva tuotanto ja varastomateriaalien saatavuus ovat keskeisessä asemassa, jotta aikatauluissa pysytään ja projektit saadaan valmiiksi ajallaan. Ennustamisella pystytään myös pienentämään kustannuksia ja riskejä, joita toimintaan liittyy.

Tämän diplomityön tarkoituksena oli tutkia suuren suomalaisen projektiliiketoimintaa harjoittavan yrityksen varastohallintaa ennustamisen näkökulmasta. Tutkimuksessa tutkittiin varastoitavien materiaalien kysynnän ennustettavuutta ja tämän avulla saavutettavaa parempaa saatavuutta. Tutkimuksen tavoitteena oli selvittää mitä varastonimikkeiden ennustaminen vaatisi ja mitä siinä pitäisi ottaa huomioon. Tutkimuksen yhtenä tavoitteena oli myös selvittää, onko varastoitavien materiaalien kysynnän ennustamisella mahdollista saavuttaa hyötyjä varastohallinnassa. Tutkimuksen yhtenä tavoitteena oli lisäksi selvittää kaupallisten ennustusjärjestelmien sopeutus kohdeyrityksen tilanteeseen.

Tutkimuksessa perehdyttiin aiempiin tutkimuksiin ja yleisiin ennustamisen teorioihin. Tarkastelun perusteella huomattiin, että ennustamista ei ole juurikaan tarkasteltu projektiliiketoiminnan kannalta. Projektiliiketoiminta eroaa varastomateriaalien kulutuksen luonteen osalta merkittävästi tasaisen tuotannon liiketoiminnasta. Tässä tutkimuksessa pyrittiin huomioimaan kyseinen ristiriita ja tutkittiin teorioiden soveltuvuutta kohdeyrityksen tilanteeseen. Tutkimuksessa selvitettiin kohdeyrityksen varastomateriaalien kysynnän ennustettavuus ja testattiin erilaisten ennustusmallien toimivuus kysynnän ennustamiseen. Ennustusmallien vertailussa hyödynnettiin useampia erilaisia virhemalleja, jotta todellinen ennustettavuus ja kysynnän luonne saataisiin selville.

Tutkimuksessa saatiin selville, että kohdeyrityksen varastomateriaalit ovat suhteellisen hyvin ennustettavissa, kun huomioidaan tietyt tekijät. Tutkimuksen mukaan ennustamisessa on syytä jaotella materiaalien kysyntä eri projekteille kohdistuvaksi kysynnäksi ja ennustaa jokainen projekti erillään. Näin materiaalien kysynnän ajoittuminen on helpommin arvioitavissa aikaisempien projektien avulla. Tutkimuksessa kehitettiin myös kohdeyritykselle ennustamisprosessin viitekehys, jonka avulla pystytään parantamaan materiaalien saatavuutta ja varmistamaan ennusteiden pätevyys. Tutkimuksessa myös asetettiin rajoitteet ja vaatimukset mahdolliselle ennustusjärjestelmälle, sekä huomattiin, että markkinoilla olevista vaihtoehdoista vain harvat soveltuvat kohdeyrityksen tilanteeseen ja projektiliiketoimintaan.

Avainsanat: Kysynnän ennustaminen, varastohallinta, aikasarjaennustaminen, toimitusketjun hallinta

Tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck –ohjelmalla.

# ABSTRACT

Risto Monnonen: Demand forecasting of stock materials as a support for procurement in project business  
Master of Science Thesis, 98 pages  
Tampere University  
Master's Degree Programme in Industrial Engineering and Management  
November 2019

---

Businesses can improve their competitive advantage by preparing for the future. In order to prepare for the future, it is necessary to assess the state of the future and changes in it. Based on these estimates and forecasts, plans can be made to respond to future changes from the present. Predictability in terms of inventory management and sourcing can be seen as a key function to ensure smooth production. In the project business, smooth production and availability of inventory materials are key to staying on track and completing projects on time. Prediction can also reduce the costs and risks associated with the operation.

The purpose of this Master's thesis was to study the inventory management of a large Finnish project-based company from a forecasting perspective. The study investigated the predictability of demand for storage materials and the improved availability that can be achieved through this. The purpose of the study was to determine what inventory forecasting would require and what it should take into account. One of the aims of the study was also to determine whether the forecasting of the demand for materials to be stored could provide benefits in inventory management. In addition, one of the aims of the study was to determine the suitability of commercial forecasting systems for the target company.

The study looked at previous research and general theories of forecasting. On the basis of the review, it was found that forecasting has not been very much considered in terms of project business. The project business differs significantly from the steady-state production business in terms of the nature of inventory consumption. This study sought to address this contradiction and to examine the applicability of the theories to the situation of the target company. The study investigated the predictability of demand for warehouse materials in the target company and tested the performance of different forecasting models for forecasting demand. Several different error models were used to compare forecasting models in order to find out the real predictability and the nature of the demand.

The study found that the target company's inventory materials are relatively well predictable when certain factors are taken into account. According to the study, the demand for materials should be divided into demand for different projects and forecast each project separately. This makes it easier to estimate the timing of the consumption for materials through previous projects. The study also developed a reference framework for the forecasting process for the target company, which can improve the availability of materials and ensure the validity of the predictions. The study also set limits and requirements for a potential forecasting system, and found that only a few of the alternatives available on the market are appropriate for the target company's situation and project business.

Keywords: Demand forecasting, inventory management, time series forecasting, supply chain management

The originality of this thesis has been checked using the Turnitin OriginalityCheck service.

# ALKUSANAT

Tämä diplomityö on tehty opinnäytetyönä Tampereen yliopiston tuotantotalouden diplomi-insinöörin tutkinto-ohjelmaan. Työn tarkastajana on toiminut professori Jussi Heikkilä, jota haluan kiittää työn kommentoinnista ja työn johdattamisesta eteenpäin. Tämän lisäksi haluan kiittää toimeksiantajaa mahdollisuudesta erittäin mielenkiintoisen työn tekemiseen ja kaikkeen tukeen työn valmiiksi saamiseen. Kiitän myös muita työhöni läheisesti vaikuttaneita henkilöitä, joilla on ollut suuri rooli työni kannalta.

Turussa, 15.11.2019

Risto Monnonen

# SISÄLLYSLUETTELO

1. JOHDANTO .....	1
1.1 Tutkimuksen taustaa .....	1
1.2 Kohdeyritys .....	2
1.3 Tavoitteet ja tutkimusongelmat .....	3
1.4 Tutkimusmetodologia .....	4
1.5 Tutkimuksen rakenne ja rajaukset .....	5
2. TEORIAOSIO .....	7
2.1 Mitä on ennustaminen? .....	7
2.2 Ennustaminen päätöksenteon tukena .....	8
2.3 Ennustamisen prosessi .....	10
2.4 Ennustusten elementit .....	14
2.5 Ennustaminen varastohallinnan näkökulmasta .....	16
2.5.1 Ennustamisen merkitys varastohallinnalle .....	16
2.5.2 Varastonimikkeiden kysyntämallit .....	20
2.6 Ennustamisen eri menetelmät .....	22
2.7 Kvalitatiiviset menetelmät .....	23
2.7.1 Kvalitatiivisten menetelmien hyvät ja huonot puolet .....	24
2.7.2 Kvalitatiivisia menetelmiä .....	25
2.8 Aikasarjaennustaminen .....	27
2.8.1 Yksinkertaiset mallit .....	29
2.8.2 Tasoittavat mallit .....	30
2.8.3 Trendikorjatut mallit .....	32
2.8.4 Kausiluonteiset mallit .....	33
2.8.5 Epäsäännöllisen kysynnän mallit .....	35
2.9 Monimuuttujaennustaminen .....	38
2.10 Ennustamisen tarkkuus .....	40
2.11 Ennustemallin valinta .....	44
3. ALKUTILANNEANALYYSI .....	47
3.1 Materiaalinimikkeiden varastohallinta alkuhetkellä .....	47
3.2 Kohdeyrityksen toimitusketju .....	50
3.3 Ennustaminen alkuhetkellä .....	53
3.4 Ennustamisen tarve .....	54
4. DATAN ANALYSOINTI JA TULOKSET .....	56
4.1 Datan kerääminen .....	57
4.2 Datan puhdistus .....	58

4.3	Datan analysointi .....	59
4.3.1	Nimikkeistön ennustettavuus .....	59
4.3.2	Nimikkeistön kategorisointi.....	61
4.4	Ennustemallien vertailu .....	64
4.4.1	Kausiluonteisuuden huomioiminen.....	69
4.4.2	Kvartaali- ja vuosiennustaminen .....	73
4.4.3	Uusien nimikkeiden ennustaminen.....	78
4.5	Ennusteen luominen .....	81
4.5.1	Kvalitatiivinen oikaisu.....	84
4.6	Ennusteen käyttäminen ja tarkkuuden mittaaminen .....	84
4.7	Kohdeyrityksen ennustusprosessi .....	86
5.	PÄÄTELMÄT JA JATKOTOIMENPITEET .....	90
5.1	Tutkimuksen keskeisimmät tulokset.....	90
5.2	Suosittelvat jatkotoimenpiteet.....	91
5.3	Tutkimuksen arviointi .....	92
5.4	Suosituksat jatkotutkimukselle .....	93
	LÄHTEET.....	95

# 1. JOHDANTO

## 1.1 Tutkimuksen taustaa

Ennustamisen merkitystä ei voida korostaa liikaa. Ennusteet ovat olennaisia tekijöitä yritysten toiminnanohjauksen ja varastohallinnan kannalta (Stevenson 2014, p. 75). Lähes kaikki varastoinnin päätökset riippuvat vahvasti kysynnän ennustamisesta, ja tässä onnistumalla on mahdollista saavuttaa merkittäviä taloudellisia hyötyjä (Prak & Teunter 2019). Samaan aikaan toimintaympäristöjen kasvava kompleksisuus ja epävarmuus vaikeuttavat tulevaisuuden tilan tuntemista. Varastoa ylläpidetään ilman täyttä varmuutta tulevasta kysynnästä ja päätöksiä tehdään epävarmuuden vallitessa. (Waddell & Sohal 1994.)

Yritykset tarvitsevat tavoitteisiin päästäkseen suunnitelmia, jotka perustuvat tulevaisuuden ennusteisiin. Päätöksiä ja suunnitelmia tekevät monet eri sisäiset ja ulkoiset sidosryhmät, mikä korostaa ennusteiden tärkeyttä. Ennusteiden merkitys ei rajoitu vain varastohallintaan, vaan sen perusteella suunnitellaan myös useita muita yrityksen prosesseja. (Kolassa & Siemsen 2014.) Ennustamisen voidaan nähdä olevan eräs tärkeimmistä yrityksen toiminnoista, koska se vaikuttaa kaikkiin muihin liiketoiminnan päätöksiin. Huonot ennusteet johtavat virheellisiin päätöksiin ja jättävät yrityksen huonosti valmistuneeksi tulevaisuutta varten. Ennustaminen ja hyvien ennusteiden tuottaminen ovat yrityksille niin tärkeitä, että ne investoivat miljardeja teknologioihin, jotka voivat auttaa tulevaisuuden suunnittelussa. (Sanders 2015, pp.3-6.)

Kysynnän ennustamisen ymmärtämiseen ei riitä vain tilastollisten metodien sisäistäminen, vaan pitää myös ymmärtää miten ennusteet luodaan ja miten niitä käytetään päätöksenteossa (Kolassa & Siemsen 2014). Vaikka ennustamista käytetään pääsääntöisesti kysynnän ennustamiseen, sisältää se huomattavasti laajemman aihepiirin ennustamista. Ennusteet luovat pohjan kaikille yrityksen päätöksille, milloin kysynnän ennusteilla vaikutetaan myös monen muun toiminnon ennusteisiin. Esimerkiksi varastohallinnan kannalta kysynnän ennusteet vaikuttavat tarvittavaan varastointikapasiteetin, pääoman, henkilöstöressurssien ja tuotannon ennusteisiin. (Sanders 2015)

Tämän tutkimuksen aihe syntyi kohdeyrityksen tarpeesta tehostaa ja parantaa varastoitavien nimikkeiden hallintaa. Varastoitavien tuotteiden hallinta perustuu lähtökohtaisesti tietoon tai uskomukseen tulevasta kysynnästä (Stevenson 2014, p.77). Jos tuotteiden kysynnästä ei ole varmuutta riittävästi etukäteen, on tuotannon tarpeet vaikea täyttää.

Yrityksen sisäisen varastoinnin kohdalla tuotanto ja muut asiakkaat voivat joutua odottamaan niin kauan, että tuotannollinen aikataulu kärsii. Tällöin syntyy huomattavia kustannuksia ja haasteita aikataulullisten tavoitteiden saavuttamiseksi.

Kohdeyrityksen kilpailukentän laajentumisen ja kilpailun koventumisen seurauksena kilpailevat yritykset pyrkivät optimoimaan ja tehostamaan prosesseitaan. Myös varastohallinnalla voidaan saavuttaa kilpailuetua muihin toimijoihin verrattuna. Varastoitavien tuotteiden saatavuudella on merkittävät vaikutukset koko yrityksen toimintaan. Parhaimmillaan tuotteita on saatavilla aina kun niitä tarvitaan ja tuotanto sujuu tämän osalta hyvin. Toisaalta toimitusviivästyksillä voi olla huomattavia vaikutuksia niin taloudellisesti, tuotannollisesti sekä pidemmällä aikavälillä aikataulullisia vaikutuksia. Toistuvilla tuotepuutteilla ja viivästyksillä voi olla myös vaikutuksia asiakastytyväisyyteen ja asiakkaiden menettämiseen.

## 1.2 Kohdeyritys

Kohdeyritys on yli 250 henkilöä työllistävä teollisuuteen keskittyvä suomalainen yritys, jonka liikevaihtoluokka on yli 50 miljoonaa euroa. Yritys täten kategorisoituu suureksi yritykseksi (European Union 2015, p. 11). Yritys on osa suurempaa konsernia, johon kuuluu useampi eri maissa toimiva yritys. Yrityksen verkosto ja vaikutusalue paikallisessa sekä valtakunnallisessa mittakaavassa on merkittävä. Myös koko konsernin vaikutus globaalissa mittakaavassa konsernin toimialalla on merkittävä.

Yritys toimii teollisuuden toimialalla, ja yrityksen liiketoimintamuoto on projektiliiketoiminta. Yrityksen asiakaskenttä on globaalisti hyvin hajaantunut. Yrityksen pääsääntöinen tuotevalikoima koostuu tarkkaan suunnitelluista ja toteutetuista mittavista projekteista. Yrityksen kilpailuedut erittäin kilpaillulla toimialalla ovat hyvä projektijohtaminen, asiantuntemus ja kokemus, joustavuus ja reagointikyky sekä hyvin suunnitellut tuotantoprosessit ja verkostot. Kovasta kilpailusta huolimatta toimialan näkymät ovat hyvät. Kohdeyrityksen tilauskanta käsittää usean projektin lähitulevaisuuteen, ja sekä yrityksen että koko konsernin tavoitteena on kasvaa merkittävästi lähitulevaisuudessa.

Yrityksen toimintaa leimaa kriittisyys asiakastytyväisyyteen ja toisaalta projektien aikataulussa pysymiseen. Yritys pystyy tarjoamaan vahvasti räätälöityjä projekteja asiakkailleen suhteellisen nopealla aikataululla, ja näistä ominaisuuksista kiinni pitäminen on erityisen tärkeää. Varastohallinnan näkökulmasta tämä tarkoittaa, että tarvittavia nimikkeitä on oltava saatavilla nopealla aikataululla.



### 1.3 Tavoitteet ja tutkimusongelmat

Tutkimuksen tavoitteena on tutkia kohdeyrityksen varastonimikkeiden ennustettavuutta. Tavoitteena on selvittää, mitä kysynnän ennustaminen vaatii ja mitä siinä pitäisi ottaa huomioon. Tutkimuksen avulla pyritään selvittämään, onko nimikkeiden ennustamisella mahdollisuus parantaa kohdeyrityksen varastohallintaa. Tämän lisäksi tavoitteena on luoda karkealuonteinen viitekehys kohdeyrityksen ennustusprosessille. Tutkimuksen tavoitteisiin kuuluu myös selvittää yleisesti tunnistettujen teorioiden soveltuvuus kohdeyrityksen tilanteeseen, ja niiden hyödyntäminen varastonimikkeiden kysynnän ennustamisessa.

Yhtenä tavoitteena on myös selvittää ja kartoittaa mahdollisten ennustusjärjestelmien soveltuvuus kohdeyrityksen varastonimikkeiden ennustamiseen ja hallintaan. Kaupallisten järjestelmien ominaisuuksien yhteensopivuus tarvittavien ennustamisen toimintojen kanssa ja toisaalta tavoitteiden saavuttaminen järjestelmien avulla selvitetään osana tutkimusta. Tavoitteena on myös luoda karkealuonteinen viitekehys ennustamisen prosessille, jonka osana on mahdollista hyödyntää kaupallista ennustamiseen tarkoitettua järjestelmää.

Tutkimuksen tutkimusongelma liittyy kohdeyrityksen varastonimikkeiden ennustettavuuden selvittämiseen ja toisaalta ennustamiseen vaadittavien ominaisuuksien ja huomioonotettavien tekijöiden kartoittamiseen. Alkutilanteessa kohdeyrityksellä on heikko tietämys varastonimikkeiden tulevasta kysynnästä, mikä on osaltaan heikentänyt varastohallintaa ja yrityksen tuotantoa. Epävarmuus varastonimikkeiden tulevasta kysynnästä on nostanut kustannuksia ja lisännyt viivästyksiä nimikkeiden toimittamisessa tuotannolle ja asiakkaille.

Nimikkeiden kysynnän epävarmuudesta johtuen varastomateriaalien palveluaste on heikentynyt huomattavasti viimeisen vuoden aikana, mihin on vaikuttanut vahvasti nimikkeistön osittainen uusiminen. Tämä on näkynyt pitkissä viivästyksissä nimikkeiden toimitusajoissa. Kohdeyrityksen tuotanto on kärsinyt ja projektit ovat kohdanneet aikatauluhaasteita pitkien toimitusaikojen seurauksena. Tutkimuksen yhtenä tavoitteena onkin antaa konkreettisia ratkaisuehdotuksia näiden ongelmien voittamiseksi.

Tutkimuksen tavoitteena on tutkia nimikkeiden kysyntää eikä todellista kulutusta projekteissa. Jokainen projekti vaatii tarkan määrän varastonimikkeitä valmistuakseen. Tutkimuksen lähtökohtana voisi olla projektien kokonaiskulutuksen ennakoiminen, mutta hankinnan ja varastoinnin kannalta merkityksellinen kokonaiskysyntä ei vastaa tätä määrää. Tuotanto ja alihankkijat saattavat pyytää materiaaleja enemmän kuin todellinen tarve on, jotta ne varmasti riittävät tarpeisiin. Tämän takia tutkimuksessa ei keskitytä projektien

todelliseen materiaalinkulutukseen, vaan toimitusketjun kannalta kriittiseen nimikkeiden kokonaiskysyntään.

## 1.4 Tutkimusmetodologia

Tutkimus on tapauskohtainen tutkimus, jossa tutkitaan yhden organisaation tiettyä ongelmaa. Tutkimuksen tavoitteena on löytää ratkaisuja ja tuloksia ainoastaan kyseisen yrityksen tilanteeseen. Tutkimuksen taustalla vaikuttava filosofia on realismi, joka tarkoittaa, että tarkastellaan faktoja ilman ihmisten uskomuksia ja ajatuksia vaikuttamassa tuloksiin (Saunders et al. 2016). Tutkimuksen lähestymistapa on lähtökohtaisesti objektiivinen. Tämä tarkoittaa, että tutkija ei ole osa kohdeorganisaatiota tavalla, joka vaikuttaisi tutkimukseen (Saunders et al. 2016). On kuitenkin syytä huomioida, että tutkija työskentelee osana kohdeyritystä, mikä saattaa vaikuttaa tutkimuksen tuloksiin. Samoin tutkijan uskomuksilla ja mielipiteillä voi olla vaikutuksia tutkimuksen kulkuun. Näiden vaikutusten oletetaan kuitenkin olevan marginaalisia.

Tutkimuksen tieteellinen lähestymistapa on deduktiivinen. Tässä tavassa yleisistä ja perustavanlaatuisista teorioista johdetaan tapauskohtaista tutkimusta ja tilannetta koskevia johtopäätöksiä (Saunders et al. 2016). Kyseisen tutkimuksen valossa tämä tarkoittaa, että ensin tutkitaan ja esitellään ennustamisen teoriaa ja merkitystä yrityksille, minkä jälkeen analysoidaan näiden teorioiden soveltuvuutta kohdeyrityksen tilanteeseen. Tutkimuksen deduktiivisuus näkyy varsinkin siinä, että tutkitaan sopivatko aiemmat teoriat kohdeyrityksen tilanteeseen sellaisenaan vai eroaako se merkittävästi.

Teoriaosio suoritetaan kirjallisuuskatsauksena, jossa tutkitaan tieteellisten julkaisujen ja kirjallisuuden avulla vallitsevia näkemyksiä ja menetelmiä yritysten varastohallintaan ja ennustamiseen. Toinen osio yrityksen alkutilanteesta suoritetaan empiirisenä laadullisena tutkimuksena. Tutkimuksen kolmas osio suoritetaan empiirisenä kvantitatiivisena tutkimuksena, jossa kohdeyrityksestä kerätyn datan avulla tutkitaan teorioiden paikkansapitävyyttä kohdeyrityksen tilanteessa.

Kohdeyrityksen alkutilanteen selvittämiseksi suoritetaan alkutilanneanalyysi. Analyysin avulla selvitetään kohdeyrityksen toimitusketjun nykytilaa ja varastohallinnan toimenpiteitä. Alkutilanneanalyysissä haastatellaan sekä kohdeyrityksen varastohallinnasta vastaavia asiantuntijoita että suurimpien toimittajien edustajia. Haastattelu suoritetaan avoimena ja vapaamuotoisena teemahaastatteluna, jossa laajahkojen avaavien kysymyksien avulla pyrittiin selvittämään lähtötilanne ja virallisten prosessien ja toimintatapojen taustalla vaikuttavat tekijät. Haastattelut nauhoitetaan, jotta haastatteluiden sisältöihin pystytään tarvittaessa palaamaan myöhemmin.

Kvantitatiivisen empiirisen tutkimukseen kerätään dataa kohdeyrityksen järjestelmistä. Datan analysoinnilla tutkitaan datan luonnetta ja testataan teorioiden soveltuvuutta. Tuulosiosiossa pohditaan datan analysoinnin ja aiempien teorioiden testaamisen avulla näiden soveltuvuutta kohdeyrityksen tilanteeseen. Tutkimuksessa otetaan kantaa myös kerättävän aineiston paikkansapitävyyteen ja koko tutkimuksen validiteettiin. Näiden useiden erilaisten tutkimusmetodien avulla tutkimuksesta muodostuu niin kutsuttu monimetodinen tutkimus, jonka avulla pystytään suosittelemaan kohdeyritykselle jatkotoimenpiteitä ongelmien ratkaisemiseksi.

## **1.5 Tutkimuksen rakenne ja rajaukset**

Tutkimus koostuu neljästä eri luvusta. Ensimmäisessä osiossa käsitellään aiempaa kirjallisuutta ja teoriaa aiheesta. Tässä luvussa pohditaan ennustamisen merkitystä yrityksen ja varastohallinnan kannalta sekä selvitetään ennustamisen ja ennusteiden ominaisuuksia. Teoriaosiossa myös esitellään ennustamisen eri menetelmät niin kvalitatiivisen kuin kvantitatiivisen ennustamisen näkökulmasta. Teoriaosiossa esitellään myös ennustamisen tarkkuuden mittaamisen eri menetelmiä ja ennustemallin valintaa mittaamisen avulla.

Toisessa osiossa esitellään kohdeyrityksen nykytilannetta. Luvussa käydään läpi tutkimusongelmaa tarkemmin ja pohditaan kohdeyrityksen prosessien ja toimintatapojen vaikutuksia. Luvussa myös pohditaan kohdeyrityksen alkutilanteessa hyödyntämiä ennustamisen keinoja ja niiden vaikutuksia koko yrityksen toimitusketjuun. Tutkimuksen kolmannessa osiossa keskitytään kohdeyrityksestä kerätyn datan analysointiin ja analysoinnin tuloksiin. Tässä luvussa tutkitaan yrityksen varastonimikkeiden ennustettavuutta ja nimikkeiden kulutuskäyttäytymistä. Analyysin perusteella otetaan kantaa siihen, mitä pitää huomioida nimikkeiden kysyntää ennustettaessa.

Tutkimuksessa keskitytään ennustamiseen päätöksenteon tukena. Suunnittelu ja ennusteiden avulla tehtävät päätökset jätetään kohdeyrityksen ja sidosryhmien tehtäväksi. Ennustaminen pidetään objektiivisena, eikä tulevaisuuden tilaan pyritä vaikuttamaan. Ennustamisen mahdollisuuteen ja edellytyksiin vaikuttaviin tekijöihin sekä sitä tarkentaviin toimenpiteisiin voidaan tällä tutkimuksella kuitenkin ottaa kantaa.

Tutkimus rajataan koskemaan vain kohdeyritystä. Näin poissuljetaan toimittajien ja muiden sidosryhmien vaikutukset ja toisaalta myös tarpeet. Usein ennusteilla ja ylipäättään kysyntään varautumisella on mittavia vaikutuksia koko toimitusketjuun ja yrityksen sidos-

ryhmiin (Chen et al. 2000). Ennusteiden käyttäminen ja tuotannon varmistaminen materiaalien saatavuuden varmistamiseksi jätetään toimitusketjun muiden toimijoiden tehtäväksi. Tämän tutkimuksen ennustaminen nähdään vain syötteenä muille toiminnoille.

## 2. TEORIAOSIO

Tässä luvussa esitellään tutkimuksen teoreettinen tausta aiempien tutkimusten ja teorioiden pohjalta. Luvussa perehdytään ennustamisen merkitykseen, erilaisiin ennustusmalleihin, ennustamiseen varastonhallinnan ja hankinnan näkökulmasta sekä ennustusten arviointiin. Aluksi pohditaan ennustamista yleisellä tasolla, sekä ennustamista yritysten näkökulmasta: mihin kaikkeen ennustamista tarvitaan ja mikä sen rooli yrityksissä on.

### 2.1 Mitä on ennustaminen?

Ennustaminen on hyvin yleistä niin ihmisten jokapäiväisessä elämässä, kuin yritysten toiminnassa. Joka kerta, kun teemme arvion tulevaisuuden tilasta kuten säästä, ajoajasta kaupungin läpi tai presidentinvaalien tuloksesta, ennustamme tulevaisuutta. (Sanders 2015.) Ennusteiden pohjana käytämme kokemuksiamme, muiden tekemiä arvioita tai puhtaasti arvaamalla vaihtoehtojen joukosta. Myös yritysten toimintaan liittyy paljon ennustamista. Ennustamista voidaan tehdä lukuisiin eri tarpeisiin, ja ennustamiseen on olemassa niin erilaisia tilastollisia malleja kuin asiantuntijoiden ja työntekijöiden omia arvioita (Evans 2008).

Yleisesti ennustaminen on tärkeä funktio, jota käytetään lukuisille eri aloille. Ennustamista pyritään tekemään niin yhteiskuntatieteiden, lääketieteen, talouden, ympäristötieteiden, rahoituksen, politiikan, hallitusten ja teollisuuden näkökulmasta (Montgomery et al. 2015, p.2). Ennusteita ja ennustamista tarvitaan aina, kun tehdään päätöksiä – varsinkin kun päätetään asioista, joilla on vaikutuksia pitkällä aikavälillä. Yritysten näkökulmasta ennustamista tarvitaan hyvin moniulotteisten päätösten tueksi. Ennustamisella pyritään muun muassa varautumaan tulevaan kysyntään, talouden vaihteluihin, kilpailijoiden toimiin tai sidosryhmien vaatimuksiin ja muutoksiin. (Armstrong, Jon Scott 1985.)

Ennustamista hyödynnetään useissa yrityksen eri toiminnoissa. Ennustukset voivat luoda pohjan esimerkiksi budjetoinnille, kapasiteetin suunnittelulle, tuotannolle, varastoinnille, henkilöstölle ja hankinnalle. Usein päätökset joissain toiminnoissa, vaikuttavat myös muihin päätöksiin, jolloin yhteiseen ennusteeseen luottaminen on tärkeää. (Stevenson 2014, pp.75-77) Yhteiseen ennusteeseen luottaminen aiheuttaa kuitenkin ennustusten tarkkuudelle paineita. Kuten Sanders (2015, p.4) toteaa, heikot ennusteet

johtavat virheellisiin liiketoiminnallisiin päätöksiin. Näin ollen huonot ennustukset esimerkiksi kysynnän suhteen voivat aiheuttaa suuria ongelmia koko organisaation tasolla, ja jopa pakottaa yrityksen konkurssiin.

Kaikilla ennustuksilla on samankaltaisia ominaisuuksia, jotka pätevät hyvin erityyppisissä tilanteissa ja organisaatioissa. Stevensonin (2014, pp.78-79) mukaan yleisesti ennustusten ominaisuuksia ovat:

1. Ennustukset eivät ikinä ole täydellisiä.
2. Ennustusmallit olettavat tiettyjen aikaisempien kausaalisten systeemien jatkuvan myös tulevaisuudessa.
3. Ryhmäkohtaisella ennusteella on taipumusta olla tarkempi kuin yksittäisen nimikkeen.
4. Ennustustarkkuus pienenee aikajakson kasvaessa.

Ensimmäisen ominaisuuden mukaan ennustukset ovat aina vain arvioita, ja kaikki ennusteet sisältävät jonkinlaisen virheen (Evans 2008, p.3). Toinen ominaisuus liittyy vahvasti aikasarjaennustamiseen, johon palataan myöhemmin tässä luvussa. Kolmas huomio liittyy siihen, että ryhmäkohtaisessa ennustamisessa ennustusvirheillä on tapana kumota toisiaan. Viimeinen ominaisuus taas painottaa lukuisten muuttujien vaikutusta ennustustarkkuuteen aikajakson kasvaessa. (Stevenson 2014, pp. 78-79.)

Myös Sanders (2015, pp.18-19) painottaa ennustusten ominaisuuksia. Hänen mukaansa merkittävimmät ominaisuudet ovat, kuten edellä mainittu, ennustusten epätäydellisyys, ennusteen paraneminen ryhmittämällä ja ennusteen heikkeneminen aikajakson kasvaessa. Sandersin mukaan näiden ominaisuuksien ymmärtäminen on tärkeää, koska ne kertovat, mitä ylipäätään voidaan odottaa ennusteilta. Toisaalta hän korostaa ominaisuuksien merkitystä ennusteiden odotusten asettamisen kannalta. Esimerkiksi pitkän aikavälin ennustusten ei voida olettaa olevan yhtä tarkkoja kuin lyhyen aikavälin.

## **2.2 Ennustaminen päätöksenteon tukena**

Yrityksissä ennustamisen rooli on noussut merkittävästi. Yritysten kasvu, toimintaympäristön dynaaminen luonne ja yksittäisten päätösten merkityksen kasvu korostavat ennustamisen tärkeyttä (Waddell & Sohal 1994). Feiginin (2011, p.15) mukaan on kuitenkin hämmästyttävää, kuinka vähän yrityksissä panostetaan yleisesti ennustamiseen. Ennustaminen jätetään usein irralliseksi tehtäväksi esimerkiksi ohjelmistoille tai tukitoiminnoille. Ennustamista ei juurikaan kohdella liiketoimintaprosessina sillä vakavuudella kuin pitäisi. (Feigin 2011, p.15.) Tämän lisäksi päätöstentekijät usein jättävät huomioimatta ennus-

teet ja luottavat mieluummin omiin arvauksiinsa. Yleensä organisaatioissa ne, jotka ymmärtävät liiketoimintaa, eivät ymmärrä logaritmien päälle ja toisinpäin. Tämä aiheuttaa ristiriitoja esimerkiksi ennustusten tulkintaan: päätöksentekijät sekoittavat ennusteet usein suunnitelmiin, tavoitteisiin tai päämääriin. (Kolassa & Siemsen 2014, p.3.)

Ennustamisen tärkeys ja merkitys yrityksille johtuu pääsääntöisesti siitä, että sitä käytetään niin monen eri toiminnan ja päätöksentekotilanteen taustalla. Päätöksiä tehdään muun muassa toiminnanohjauksessa tuotannon aikatauluttamisessa tai varastojen hallinnassa, markkinoinnissa, riskien hallinnassa varautumalla tulevaisuuteen ja prosessihallinnassa varmistamalla prosessien jatkuvuus ja tehokkuus. (Montgomery et al. 2015, pp. 3-4.) Ennustusten laajan käytön seurauksena niiden tarkkuus korostuu. Vaikka ennustukset eivät ikinä olekaan täydellisiä kuten Stevenson (2014, p.79) toteaa, päätöksentekijä voi tietyillä olettamuksilla ja analysoimalla historiaa ennakoida tulevaisuutta kohtuullisella varmuudella. Näin päätöksien tekeminen on tietyn epävarmuuden rajoissa perusteltavissa.

Ennustamisen tarkkuuden merkitys korostuu päätöksenteossa. Mitä tarkempi ennustus on, sitä paremmin päätökset ovat perusteltavissa ja informoituja mahdollisista tulevaisuuden tiloista. (Stevenson 2014, p.75.) Ennustukset ja ennustaminen ovat yleisesti ottaen syötteitä suunnittelulle, jonka avulla tulevaisuuteen joko pyritään varautumaan tai sitä pyritään muuttamaan (Waddell & Sohal 1994). Suunnitelma voi täten olla vain yhtä hyvä kuin ennuste antaa sille mahdollisuuden. Toisaalta ennustus ilman suunnitelmaa voidaan nähdä täysin turhaksi. Päätöksien tekeminen ennustusten pohjalta luo perustan ennustusten olemassaololle ja niiden tekemiselle.

Kun puhutaan yritysten tarpeista ennakoida tai varautua tulevaisuuteen, on hyvä pitää erillään käsitteet ennustaminen (forecasting) ja suunnittelu (planning), jotka usein sekoitetaan keskenään (Sanders 2015, p.8). Ennustaminen on objektiivinen näkemys tulevaisuuden tilasta, kun taas suunnittelulla pyritään vaikuttamaan siihen, minkälainen tulevaisuuden tila on. (Armstrong, Jon Scott 1985.) Kuten Hogarth ja Makridakis (1981) selventävät, tarvitsee suunnittelu päätöksenteon toimintona

- tavoitteita ja arvoja
- vaihtoehtoisia toimintatapoja
- vaihtoehtojen arviointia
- valitun vaihtoehdon täytäntöönpanon
- toteutetun suunnitelman seuranta ja ohjaamista.

Heidän mukaansa ennusteita tarvitaan sekä vaihtoehtojen toimintatapojen luomisessa että arvioinnissa ja tulevaisuuden ulkoisen ympäristön ennakoimisessa.

Jos johtaja organisaatiossa haluaa ennustuksen, hän usein tarkoittaa suunnitelmaa, jolla tietty ennustuksen mukainen tulevaisuuden tilanne saadaan parhaiten hyödynnettyä (Armstrong, Jon Scott 1985). Ennustus pyrkii vastaamaan kysymykseen, mitä tulevaisuudessa tulee tapahtumaan. Suunnitelma taas perustuu ajatukseen siitä, että toimimalla tietyllä tavalla nyt, päätöksentekijä voi vaikuttaa tulevaisuuden tilanteeseensa. (Waddell & Sohal 1994.) Suunnitelman ja ennusteen ero on hyvä tiedostaa organisaation sisällä väärinymmärrysten välttämiseksi. Ennusteet eivät ole suoraan tavoitteita tai hyviä vaihtoehtoja, vaan ainoastaan objektiivisia arvioita tulevasta.

## 2.3 Ennustamisen prosessi


Eräs keskeinen näkemys ennustamiseen on, että ei ole olemassa hyviä tai huonoja ennustuksia. On vain olemassa hyviä tai huonoja tapoja luoda ennustuksia ja käyttää niitä. Ennustusten luomisessa pitää saada hyödynnettyä kaikki oleellinen ja saatavilla oleva informaatio, sillä se on kaikki kaikessa pienentämään epävarmuutta, joka ennustuksiin liittyy. (Kolassa & Siemsen 2014, p.4.) Tämä on suhteellisen filosofinen lähestymistapa ennustamiseen, ja se on helppo kyseenalaistaa yksinkertaisesti vertaamalla ennusteiden tuloksia toteutuneisiin arvoihin ja siten määritellä ennustusten pätevyys. Ennusteisiin liittyy kuitenkin niin paljon muuttujia ja epävarmuutta, että yksittäisten ennusteiden tarkastelu on usein harhaanjohtavaa.

Jos ennustus eroaa merkittävästi toteutuneesta, mutta ennustuksen luomisessa on otettu tehokkaasti huomioon kaikki saatavilla ollut informaatio, on suuri todennäköisyys, että on yksinkertaisesti käynyt huono tuuri. Toisaalta, jos ennustus osuu kohdilleen, mutta ennuste on luotu käyttämättä merkittäviä tietoja hyväksi, on ennustaja saattanut vahingossa osua oikeaan. (Kolassa & Siemsen 2014, p.4.) Ennusteiden luomista on syytä tarkastella prosessina, johon sisältyy tiettyjä vaiheita ja hyväksi havaittuja säännöllisyyksiä.

Vaikka ennustuksia ei voidakaan arvioida puhtaasti niiden tulosten perusteella, ennustusprosessien tehokkuutta voidaan kuitenkin kyseenalaistaa, ja sujuvan päätöksenteon tukena on oltava selkeä ennustusprosessi. Huonot ennustukset johtuvat useimmiten huonosta ennustamisen prosessista, joka ei ota huomioon kaikkia saatavilla olevia tietoja. (Kolassa & Siemsen 2014, pp.7-8.) Toisaalta ennustusprosessien tehokkuudessa ja suorituskyvyn mittaamisessa on hyvä huomioida informaation saatavuus. Ennustusprosessi voi olla ainoastaan niin hyvä kuin mitä tietoja on saatavilla. Jos esimerkiksi organisaation ei ole mahdollista saada tarvittavia tietoja kustannustehokkaasti, ei ennustusprosessi ja täten ennustuksetkaan voi olla laadukkaita.



Ennustamisen prosessinomaista luonnetta on tutkittu merkittävästi (esimerkiksi Feigin 2011; Stevenson 2014; Montgomery et al. 2015; Sanders 2015). Ennustusprosessit eroavat toisistaan jonkin verran, mutta pääpiirteiltään niissä on nähtävissä samat merkittävimmät vaiheet. Ennustusprosessin teoreettisena viitekehyksenä esitellään tässä tutkimuksessa Sandersin (2015, p.20) malli, joka on nähtävissä kuvassa 1. Tämä malli kuvaa hyvin prosessin keskeisimmät osat, ja se soveltuu yleisluontoiseksi viitekehykseksi lähes jokaiseen tilanteeseen.



**Kuva 1.** Ennustusprosessi (Mukaillen Sanders 2015, p.20).

Sandersin (2015, p.20) ennustusprosessi sisältää 6 erillistä vaihetta. **Ensimmäisessä vaiheessa** pyritään tunnistamaan ongelma, johon ennustusta tarvitaan. Tässä vaiheessa määritellään myös aikajänne, joka halutaan ennustaa sekä datan keräämisen ajankohta. Stevensonin (2014, p.79) prosessimallissa ensimmäinen vaihe on samankaltainen, mutta siinä korostetaan vielä enemmän ennusteen tarkoituksen selvittämistä. Esimerkiksi kysymykset mihin ennustetta käytetään ja milloin sitä tarvitaan, kuvastavat hyvin tämän vaiheen tarkoitusta. Stevensonin mukaan tämä vaihe myös määrittää halutun ennusteen tarkkuuden ja siten myös ennustamiseen tarvittavien resurssien määrän. Hän myös eriyttää eri vaiheiksi ennustamisen tarkoituksen ja aikajakson määrittämisen.

**Datan puhdistusvaiheessa** pyritään varmistamaan datan paikkansapitävyys ja toisaalta varmistamaan ennustuksen pätevyys. Ennustuksen tulokset ovat vain niin hyviä kuin data mahdollistaa. Datan puhdistus sisältää muun muassa puuttuvan informaation korvaamisen, poikkeavuuksien ja erityistapauksien selvittämisen sekä näiden oikaisemisen. (Sanders 2015, pp.21-22.) Kuvan 1 prosessimallin vaiheiden yksi ja kaksi välille on hyvä huomioida myös datan kerääminen, mikä ei ole itsestäänselvyys. Datan kerääminen voi vaatia huomattavaa vaivannäköä (Stevenson 2014, p.79). Dataa ei ole aina saatavilla tai sen hankkiminen vaatii merkittäviä resursseja. Saatavilla oleva data puolestaan asettaa rajoituksia ennustusmallille ja sen tarkkuudelle. (Hanke et al. 2001, p.5.)

Ennustusprosessin kolmas vaihe liittyy **datan analysointiin**. Tämä vaihe on hyvin yleinen eri ennustusprosesseille. Kvantitatiivisen datan tapauksessa analysointi käsittää

muun muassa selkeiden toistuvien kaavojen tunnistamista. Tällaisia kaavoja ovat esimerkiksi trendit, kausivaihtelu, syklisyys ja tasaisuus. (Sanders 2015, pp.22-23; Montgomery et al. 2015, pp.14-15) Vaihteita kaksi ja kolme voidaan usein tehdä samanaikaisesti. Datan puhdistus, virheiden analysointi, poikkeuksien havaitseminen ja näiden selvittäminen sekä analysoidun datan tulkitseminen mahdollisten ennustusmallien näkökulmasta liittyy vahvasti datan analysoinnin ja puhdistamisen vaiheisiin (Feigin 2011, p.22).

Datan analysoinnin jälkeen seuraa **ennustusmallin valinta**. Usein tämä tarkoittaa tiettyä matemaattista mallia, joka pyrkii hyödyntämään datan analysoinnissa havaittuja lainalaisuuksia ja toistuvia kaavoja. Malleja valitaan yleensä muutama, joiden tuloksia vertailemalla valitaan paras mahdollinen. (Sanders 2015, p.24.) Ennustusmalli on mahdollista myös kehittää itse aikaisempien vaiheiden avulla. Tavoitteena neljännellä vaiheella on mahdollisimman suuri ennustustarkkuus ja toisaalta ennustusvirheen minimoiminen. Usein yksinkertaiset mallit ovat helpommin ymmärrettävissä ja toisaalta saavat päätöksentekijöiden tuen taakseen. Monimutkaisemmilla malleilla on tapana kuitenkin saada aikaan parempia ennusteita. (Hanke et al. 2001, p.5.) Toisaalta jotkin tutkimukset myös puoltavat yksinkertaisempien mallien olevan tarkempia (Green & Armstrong 2015).

Ennustusmallin valinnassa on syytä huomioida ainakin: datan ja informaation määrä sekä saatavuus, haluttu ennustustarkkuus, ennustettava aikajänne ja datan säännölliset kaavat (Sanders 2015, pp.24-25). Ennustusmalleja on lukuisia ja väittely parhaimmista malleista on kiivasta. Yhteistä linjaa ei ole kehittynyt edes yksinkertaisimpien tuotteiden kysynnän ennustamiseen. (Feigin 2011, p.27.) Montgomery et al. (2015) jakavat neljännen vaiheen kahteen osaan: mallien valitseminen ja validointi. Validoinnilla he tarkoittavat ennustusmallin testausta historiadataan. Tämä toteutetaan usein jakamalla kerätty data kahteen osaan: sovitus- ja ennustussegmenttiin. Sovitussegmentissä pyritään valitsemaan parhain mahdollinen malli, joka myötäilee historiadataa ja joka optimoidaan niin, että ennustusvirhe on mahdollisimman pieni. Ennustussegmentillä pyritään varmistamaan mallin toimivuus simuloimalla ennustus uudelle aikasarjalle ja mittaamaan ennustustarkkuus. (Montgomery et al. 2015, p.15.)

**Ennusteen luomisessa** valitulla mallilla luodaan ennuste halutulle aikavälille. Tähän käytetään usein jotain tilastollista järjestelmää, joka pystyy nopeasti laskemaan ennusteen suuresta datamäärästä. Vaikka järjestelmä laskisi automaattisesti halutun ennusteen, on käyttäjän hyvä tiedostaa, mitä tietoja se käyttää ja missä muodossa tulokset ovat. (Sanders 2015, p.25.) Ennustuksen käyttäjän on hyvä myös ymmärtää, miten ennustusmallia käytetään. Mallin ja järjestelmän käytöstä pitäisi tulla mahdollisimman rutiniinomaista. Ennusteen luomisen jälkeen pitääkin varmistaa datan saatavuus myös jatkossa, mikä mahdollistaa toistuvan ennustamisen. (Montgomery et al. 2015, pp.15-16.)

**Ennusteen tarkkuuden mittaaminen** on prosessin viimeinen vaihe. Tarkkuutta mitataan yleisesti ennusteen virheen avulla. Tarkkuuden mittaaminen on kriittinen vaihe, sillä ennustaminen on jatkuva prosessi, joka muuttuu jatkuvasti uuden informaation ja datan ilmestyttyä. Ennustevirheen mittaamista pitäisi hyödyntää prosessin kehittämisessä. (Sanders 2015, p.25.) Tarkkuuden mittaamiseen voidaan käyttää useita erilaisia ennustevirheitä, ja näitä analysoimalla voidaan päätyä muuttamaan käytettyä ennustusmallia. (Hanke et al. 2001, p.5.) Myös ennusteen tarkkuuden mittaamisen pitäisi olla jatkuva prosessi, jolla varmistetaan ennustusprosessin tyydyttävä taso (Montgomery et al. 2015, p.16.)

Ennustusprosessin pitäisi lähtökohtaisesti olla iteratiivinen. Ennustamisen luonteeseen kuuluu, että olosuhteet muuttuvat ajan kuluessa, milloin malli, joka toimi aiemmin, saattaa heikentyä jatkossa. (Montgomery et al. 2015, p.16.) Kuvassa 1 tämä prosessin iteratiivisuus kuvataan nuolella tarkkuuden mittaamisen ja datan analysoinnin välillä. Tämä tarkoittaa, että uusi data pitää analysoida ja tunnistaa mahdolliset muutokset esimerkiksi kysynnän trendin tai kausivaihtelun osalta. (Sanders 2015, pp.22-25.) Jos halutaan kertaaluontoinen ennustus, ei prosessin iteratiivisuudelle ole tarvetta. Muussa tapauksessa prosessi palaa useimmiten datan keräysvaiheeseen ennustuksen ja sen mittaamisen jälkeen. Usein uuden datan keräys ja sen analysointi ennustusmallin valintaan voidaan suorittaa automaattisesti käytetyllä järjestelmällä (Feigin 2011, pp.27-28).

Ennustusprosessilla on merkittävä vaikutus ennustusten laatuun. Kuten aiemmassa luvussa mainittiin, ennustuksia käytetään jatkuvasti päätöksenteon tukena. Jos kunnollista ennustusprosessia ei yrityksessä ole, syntyy tätä korvaamaan muita huonompia vastaavanlaisia prosesseja (Kolassa & Siemsen 2014, p.3). Tällaisia prosesseja voivat olla esimerkiksi päätöksentekijöiden omien arvioiden ja mieltymysten käyttäminen tai puhtaasti reaktiivinen suhtautuminen kysynnän vaihteluun.

Ennustamisen tutkimusten mukaan ennustamisen tekniikat eivät ole riittäviä ennustamistarkkuuden parantamiseksi, elleivät ne ole täydennetty tietyillä asianmukaisilla menetelmillä ja asennoitumisella ennustamisprosessin johtamiseen (Moon et al. 2003; Danese & Kalchschmidt 2011). Tehokkaalla ennustusprosessilla on myös positiivisia vaikutuksia koko yrityksen tehokkuuteen. Tämä perustuu luotettaviin ennusteisiin sekä myös toisaalta tiedon keräämisen ja analysoinnin vaikutuksiin. Systemaattinen datan kerääminen useista eri lähteistä yhdessä sopivien data-analyysien kanssa saattavat olla hyödyllisiä, koska ne tarjoavat muille toiminnoille hyödyllistä tietoa. Tämän lisäksi ennustusprosessi tarjoaa mahdollisuuden paremman ymmärryksen luomiseen ja saavuttamiseen liittyen markkinoiden dynaamisuuteen sekä kysynnän ja tiettyjen tekijöiden välisiin suhteisiin. (Danese & Kalchschmidt 2011.)

Ennustusprosessin rooli onkin yrityksissä hieman muuttunut. Enää pelkät ennustustulokset eivät ole ainoa prosessista saatava hyöty, vaan myös prosessin antama markkinatieto ja datan keräämisen hyödyt muille toiminnoille korostavat ennustusprosessin merkitystä. Yleisesti myös ennustusprosessin käyttäminen osana yritysten ennustamista ja päätöksentekoa parantaa ennustusten tarkkuutta merkittävästi. Tämä painottaa ennustusprosessin perusteellisen suunnittelun tärkeyttä yrityksissä. (Danese & Kalchschmidt 2011.) Ennustusprosesseista on hyvä muistaa, että ne ovat hyvin yritys- ja tilannekohtaisia. Jokin malli ei välttämättä toimi yhtä hyvin toisessa yrityksessä tai tehokkaan prosessin rakentaminen voi viedä eri määrän resursseja eri yrityksissä.

## 2.4 Ennustusten elementit

Kuten edellä mainittiin, ennustusten tehokkuutta ja sopivuutta testataan ennustustarkkuuden ja –virheen avulla. Tämän lisäksi ennustuksilla voidaan nähdä olevan erilaatuisia ominaisuuksia ja piirteitä. Myös ennustusprosesseilla on erilaisia piirteitä, joiden avulla ennustuksia voidaan arvioida ja parantaa. Stevensonin (2014, p.78) määrittämät ennustusten eri elementit ovat:

- Ennustuksen ajoitus
- Ennustuksen tarkkuus
- Ennustuksen luotettavuus
- Ennustustulosten yksiköt
- Ennustustulosten esittämismuoto
- Ennustustekniikan yksinkertaisuus ja
- Ennustamisen kustannustehokkuus

**Ennustuksen ajoitus** liittyy ennustuksesta saatavan tiedon hyödyntämiseen. Jotta ennustuksen tuloksiin on riittävästi aikaa reagoida, pitää ennustamisen tapahtua riittävän ajoissa (Stevenson 2014, p.78). Samoin hyvä ennustus ennustaa ajallisesti riittävän pitkälle tulevaisuuteen. Aikajänne ei saa kuitenkaan olla liian pitkä, jotta esimerkiksi ennustusmallin valinta ei vaikeudu. Pidentämällä aikajännettä nostetaan myös ennustuksen kustannuksia ja monimutkaisuutta. (Georgoff & Murdick 1986.)

Toisaalta pidentämällä ennustuksen aikajännettä, heikennetään **ennustuksen tarkkuutta**. Ennustuksen tarkkuus liittyy suoraan ennustuksesta saatavan tuloksen ja toteutuneen arvon eroavaisuuteen. Hyvän ennustusprosessin pitäisi tämän lisäksi ottaa kantaa ennustustarkkuuteen esimerkiksi käyttämällä erilaisia luottamusvälejä. Tämä vaihtelee huomattavasti eri ennustusmallien välillä, mikä mahdollistaa mallien vertailun.

(Stevenson 2014, p.78.) Eräs tarkkuuteen liittyvä elementti on ennustustulosten ilmaismuoto. Ennuste voidaan esittää esimerkiksi yksittäisenä arvona, kohtuullisena vaihteluvälinä mahdollisille arvoilla tai mahdollisten arvojen todennäköisyysjakaumana. Ilmaismuodon valinnassa pitää huomioida eri vaihtoehtojen kustannukset sekä mahdolliset hyödyt. (Diebold 1998.)

**Ennustuksen luotettavuus** liittyy ennustusprosessin pidempiaikaiseen tarkkuuden vaihteluun. Luotettavuutta ei kannata mitata yhden ennusteen perusteella vaan vasta pidempiaikainen ennustusprosessin tarkastelu antaa kuvan sen luotettavuudesta. Ennustusmalli, joka toimii hyvin epäsäännöllisesti halutulla tarkkuudella jättää päätöksentekijät epävarmaksi joka kerta, kun ennustusta pitäisi hyödyntää. (Stevenson 2014, p.78.) Pidemmän aikavälin tarkastelu ennustusprosessin luotettavuutta arvioitaessa on tärkeää ennustamisen epävarman luonteen takia. Jos ennustus osuu oikeaan, voi se johtua hyvin toimivan ennustusprosessin sijaan yhden kerran ihmeestä tai ennustusprosessin ulkopuolisesta tekijästä, jota ei säännöllisestä hyödynnetä prosessissa. (Harris 2014, pp.16-17.)

**Ennustustulosten esittämiseen** kannattaa myös kiinnittää huomiota. Ennuste kannattaa esittää mielekkäässä yksikössä. Yksiköiden pitäisi vastata ennusteen käyttäjän odottamia ja toisaalta ymmärtämiä yksiköitä. Esimerkiksi kysynnän ennustaminen voidaan ilmoittaa rahallisesti, määrällisesti tai vaadittujen resurssien avulla päätöksentekijän tarpeiden mukaan. (Stevenson 2014, p.78.) Yksiköitä pitää tarkastella myös datan keräämisessä ja analysoinnissa. Yksiköiden yhteismitallistaminen on merkittävässä roolissa ennustemallin valinnan ja toisaalta luotettavan datan keräämiseksi. Vaikka data saataisiin luotettavasta lähteestä, se saattaa sisältää virheitä, jotka voivat vääristää koko ennustusprosessin ja sen tulokset. (Evans 2008, p.55.)

Toinen ennusteen esittämiseen liittyvä yksityiskohta on, että ennuste olisi hyvä esittää aina kirjallisesti. Tämä parantaa todennäköisyyttä, että kaikki ennustetta käyttävät päätöksentekijät hyödyntäisivät samaa informaatiota. Myös ennusteen tarkkuuden arvioiminen on helpompaa, kun sekä toteutuneet arvot että ennusteet ovat kirjallisesti esitetty. (Stevenson 2014, p.78.) Toisaalta voidaan nähdä, että pelkät numeeriset arvot tulevaisuudentilasta eivät tuota toivottuja vaikutuksia. Ennusteiden esittämisessä on hyvä tuoda esille ennusteisiin vaikuttavia tekijöitä ja ennusteiden luomisessa huomioituja olettamuksia. Näin ennusteiden käyttäjät pystyvät paremmin luottamaan ennusteisiin ja pohjaamaan omat päätöksensä ennusteiden varaan.

**Ennustusprosessin ja käytettävän ennustemallin ymmärtäminen** on tärkeässä roolissa ennustustehokkuuden kannalta. Tämä yleensä tarkoittaa yksinkertaisen ennustemallin ja toisaalta prosessin käyttämistä. Päätöksentekijöiden on helpompi luottaa ennusteisiin, kun he tietävät miten ennustusmallit käyttäytyvät, mitä dataa se hyödyntää ja minkälaisia rajoitteita ennustuksilla on. (Stevenson 2014, p.78.) Ennustusmallien yksinkertaisuudella ei kuitenkaan ole selvää yhteyttä ennustustarkkuuden paremmuuteen. Esimerkiksi Hanken et al. (2001) mukaan monimutkaiset mallit antavat pääsääntöisesti tarkempia tuloksia. Toisaalta Green & Armstrong (2015) tutkivat laajan tutkimusotannon avulla yhteyttä, ja huomasivat, että yksinkertaiset mallit toimivat jopa tarkemmin kuin monimutkaiset. Pääsääntöisesti voidaankin todeta, että ennustusmallien valinta ja paremmuus, on hyvin tapauskohtaista. Tärkeämpää olisikin päästä testaamaan useampaa eri mallia, joita vertailemalla parhain mahdollinen malli löydettäisiin.

**Ennustamisen pitäisi myös olla kustannustehokasta**, jolloin ennustamisen hyödyt olisivat suuremmat kuin sen vaatimat resurssit (Stevenson 2014, p.78). Tämä on ehto ennustuksen tekemiselle, mutta toisaalta myös lähtökohta ennustusprosessin kehittämiseksi. Muita ennustusten ja ennustusprosessien elementtejä ovat esimerkiksi datan saatavuus, kustannukset ja datan johdonmukaisuus (Georgoff & Murdick 1986).

## **2.5 Ennustaminen varastohallinnan näkökulmasta**

### **2.5.1 Ennustamisen merkitys varastohallinnalle**

Lähes kaikki organisaatiot pitävät varastoja. Varastoissa voidaan säilyttää esimerkiksi raaka-aineita, keskeneräistä tuotantoa tai valmiita tuotteita. Suurin osa varastotuotteista sopii johonkin näistä kategorioista, mutta eri kategorioiden osuus yrityksen varastosta vaihtelee huomattavasti. Esimerkiksi logistiikkatoimialalla toimivan yrityksen varastot eroavat merkittävästi teollisuusyrityksen varastoista. (Müller 2011.) Varaston tarkoituksena on täyttää asiakkaiden tai yrityksen oman tuotannon tarpeet siihen asti, kunnes varastoja täydennetään. Varastoitavien tuotteiden ja raaka-aineiden erilaisten kysyntäominaisuuksien takia varastohallinta on usein monimutkaista. (Muckstadt & Sapra 2010, p.2.)

Teoreettisesti optimaalisessa tilanteessa varastoja ei tarvita lainkaan, vaan asiakkaiden tuotteet valmistuvat tai saapuvat toimittajilta juuri silloin, kun tarve syntyy. Kysynnän vaihtelun, toimitusketjun läpimenoajan, toimittajien epävarmuuden, suurten eräkokojen alhaisemman hinnan ja tuotannon kapasiteetin rajoitteiden takia varastoja kuitenkin käy-

tännössä tarvitaan. (Müller 2011.) Varastoja voi olla useita erilaisia, ja niillä voidaan varautua esimerkiksi säännölliseen kysyntään, pidemmälle aikavälille sijoittuvan kysynnän täyttämiseen tai kysynnän epävarmuuden hallintaan (Muckstadt & Sapro 2010, pp.2-4).

Varastointiin ja varastonhallintaan liittyy tiettyjä perustavanlaatuisia päätöksiä, joilla varmistetaan sujuva varastointi. Ensimmäinen merkittävä päätös on varastoitavien nimikkeiden valinta. Valintaan vaikuttavat yrityksen tavoitteet ja strategia näiden tavoitteiden saavuttamiseksi. Toinen päätös on varastoitavien nimikkeiden sijainti. Yrityksillä voi olla useita eri varastopaikkoja ja esimerkiksi keskusvarasto, jossa pidetään suurinta osaa nimikkeistä. Kolmas päätös varastonhallinnassa on tilauskokojen valinta nimikkeille ja neljäs päätös tilaushetki. (Muckstadt & Sapro 2010, p.5.) Ennustamisen ja tämän työn kannalta merkittävimmät tarkasteltavat päätökset liittyvät tilauskokoisiin ja –hetkeen, sekä myös osittain nimikkeiden valintaan.

Varastointiin liittyy paljon erilaisia kustannuksia, joiden minimoimiseksi varastonhallintaa tarvitaan. Varastoinnin kustannuksia ovat muun muassa hankinta-, pito-, loppumis- ja vanhentumiskustannukset. Näiden lisäksi aiheutuu myös vastaanottamis-, tilaus-, prosessointi- ja toimituskustannuksia. (Muckstadt & Sapro 2010, pp.12-13.) Varastointikustannuksia ovat myös toisaalta henkilöstökulut ja varaston tarvitseman tilan kustannukset (Müller 2011).

Karkealla tasolla varastoinnin kustannukset liittyvät joko pito- tai hankintakustannuksiin (Müller 2011). **Pitokustannukset** sisältävät muun muassa pääoman sitoutumisen varastoitaviin tuotteisiin, tämän pääoman menettämisen muilta mahdollisuuksilta, säännölliset kustannukset kuten vakuutukset, verot, vahingot ja varaston operointikulut sekä tuotteiden vanhentumiskustannukset. Pitokustannukset vaihtelevat merkittävästi esimerkiksi nimikkeen, varastointipaikan ja teknologisen vanhentumisen riskin mukaan. Yleisesti pitokustannuksia syntyy, kun tilausmäärät ylittävät kysynnän, mikä johtaa ylijäämävarastoon. (Muckstadt & Sapro 2010, pp.13-14.) Pitokustannuksien takia optimaalista olisi ostaa tuotteet vasta silloin kun niitä tarvitaan. Useat pienet tilaukset samasta tuotteesta selvästi pienentäisivät pitokustannuksia, mutta kasvattaisivat kuitenkin hankintakustannuksia.

**Hankintakustannukset** sisältävät sekä itse tuotteen hinnasta muodostuvan osan, johon vaikuttaa usein tilattavan määrä, että tilaamisesta aiheutuvat kustannukset. Tuotteet ovat usein edullisempia tilata suurissa erissä verrattuna useisiin pieniin. Toisaalta sisäiset kulut kasvavat, kun tuotteita tilataan pienissä erissä useasti. Sisäiset kulut liittyvät olennaisesti hankintaosaston henkilöstöön ja hallintaan. (Müller 2011.) Hankinnasta ai-

heutuvat kulut voidaan nähdä vakioksi jokaiselle ostolle, ja se ei riipu tilattavasta määrästä. Organisaatioiden tavoitteena on tasapainottaa hankintakustannuksien ja pitokustannuksien suhde. (Muckstadt & Sapra 2010, pp.12-13.)

Varastonhallinta on hyvin riippuvainen tulevaisuuden ennustamisesta (Feigin 2011; Stevenson 2014; Prak & Teunter 2019). Varastointiin liittyy paljon kustannuksia, joiden minimoimiseksi ennustamista tarvitaan. Ennustamisen tavoitteena on saada oikea määrä, oikeaa nimikettä, oikeaan aikaan, oikeaan paikkaan (Müller 2011). Kun tarkastellaan varastointia laajemmassa mittakaavassa toimitusketjuna, voidaan ennustamisen tarve osoittaa. Jos asiakas ei ole valmis odottamaan sitä aikaa, joka menee tuotteen valmistamiseen ja toimittamiseen tilaushetkestä, tarvitaan ennustamista. Tällä ennakoidaan asiakkaan tarve jo ennen asiakkaan mahdollista tilausta. (Kolassa & Siemsen 2014, p.4.)

Kysynnän vaihtelu aiheuttaa tarpeen ennustusmallien hyödyntämiselle varastoinnin kannalta. Epäonnistunut ennustaminen voi johtaa varaston vajaukseen tai ylijäämään. Materiaalien, osien tai palveluiden puutteet aiheuttavat myöhästyneitä toimituksia, työn keskeytymistä, huonoa asiakaspalvelua ja mahdollisesti asiakkaiden menetyksiä. Toisaalta liian optimistiset ennusteet aiheuttavat ylijäämää, joka sitoo pääomaa ja varaston kapasiteettia. Joidenkin tuotteiden kohdalla ylijäämä voi myös vanhentua, mikä tarkoittaa suoraan menetettyä pääomaa. (Stevenson 2014, pp.78-79.)

Eri toimittajilla ja tuotteilla on eripituiset läpimenoajat, joiden avulla arvioidaan toimittajien reagointikykyä tilauksiin. Toisaalta, mitä pidempi läpimenoaika jollakin tuotteella on, sitä vaikeampi on ennustaa koko läpimenoajan kysyntää. Jos tämän lisäksi läpimenoajan pituutta ei tiedetä, nousee ennustamisen merkitys edelleen. (Muckstadt & Sapra 2010, p.12.) Tasaisen kysynnän tuotteiden ennustaminen on suhteellisen helppoa, milloin myös toimitusketju pystytään hallitsemaan kysynnän vaihtelun osalta (Bon & Leng 2009). Epäsäännöllisen kysynnän tuotteiden ennustaminen voi kuitenkin olla erittäin tärkeää, ja huonoilla ennusteilla on kalliita vaikutuksia ylijäämän tai loppuneen varaston seurauksena (Syntetos & Boylan 2005).

Huonon ennusteen seurauksena voi syntyä tilanne, jossa tuotteet loppuvat kesken. Tällaisesta tilanteesta seuraa merkittäviä vaikutuksia koko toimitusketjulle. Puutteiden takia esimerkiksi tuotanto saattaa keskeytyä, jonka seurauksena asiakkaat joutuvat mukautumaan, pahimmassa tapauksessa jopa vaihtamaan kilpailijaan. Puutteiden seurauksena voivat kasvaa myös kuljetuskustannukset, jos tiettyjä tuotteita joudutaan tuomaan kiireellisellä toimituksella. Puutteiden aiheuttamien kriisien ja ongelmien selvittämiseen kuluu



myös paljon henkilöresursseja. (Muckstadt & Sapra 2010, p.4.) Puutteiden tai myöhästyneiden toimitusten eräs merkittävä seuraus on asiakastyytyväisyyden heikentyminen. Samoin suhde toimittajiin saattaa heikentyä tiukkojen aikataulujen ja vaihtelevien tilauskokojen takia. (Feigin 2011, p.7.)

Toinen ääripää on liian optimistiset ennusteet, joiden seurauksena syntyy usein ylijäämää, joka makaa varastossa sitoen pääomaa (Muckstadt & Sapra 2010, p.13). Jossain tilanteissa varastossa makaavat tuotteet tai raaka-aineet saattavat vanhentua tai niiden kuluminen on niin hidasta, ettei varastossa pitäminen ole järkevää. Usein varastoissa makaavia tuotteita halutaan pitää, vaikka se ei taloudellisesti olisikaan järkevää. Tällaisia syitä ovat esimerkiksi nimikkeiden hankinnassa syntyneet kulut, uskomus nimikkeiden käyttämiseen tai nimikkeiden jälleenmyymiseen. Toisaalta yrityksen johdon näkökulmasta varastossa makaavilla tuotteilla on myös taloudellisia hyötyjä. Tuotteiden poistaminen varastosta vaikuttaa yrityksen kirjanpitoon, ja tämä tuotteen kirjanpitoarvo ei riipu tuotteen oikeasta arvosta. Varaston arvo myös vaikuttaa usein lainan saantiin, kun lainantajat myöntävät lainaa varasto vakuutena. (Müller 2011.)

Vanhentuneiden varastossa makaavien tuotteiden poistamisesta on kuitenkin hyötyä yritykselle. Eräs oleellinen hyöty on poistettavien nimikkeiden vapauttama tila muille tuotteille. Varaston arvo saattaa näin ollen kasvaa. Toisaalta vanhentuneet ja käyttämättömät tuotteet voidaan nähdä kustantavan tilavuutensa mukaisesti varaston vuokra- tai investointikuluista. Nimikkeiden poistaminen myös tehostaa työvoiman ja laitteiden käyttöä. Tämän lisäksi oleellinen hyöty on pääoman vapautuminen muuhun käyttöön. (Müller 2011.) Tehokkaan ennustamisen ja hyvien ennusteiden avulla ylijäämää ja nimikkeiden vanhentumista voidaan ehkäistä (Feigin 2011).

Ennustamisella varastonhallinnan näkökulmasta pyritään myös parantamaan tuotteiden saatavuutta eli toisin sanoen nostamaan palveluastetta. Palvelusaste kuvaa varaston kykyä toimittaa tuotteita asiakkaille tai tuotannolle sovitusti. Jos varasto ei pysty toimittamaan tuotteita sovitusti, syntyy tuotantoon viivästyksiä ja kustannukset nousevat. (Sanders 2015, p.570.) Usein varastoilla on tavoite välittömiin toimituksiin, mikä perustuu oletukseen, että tarvittavat tuotteet ovat valmiiksi varastoissa ja heti käytettävissä. Tämä luo tarpeen ennustaa kysynnän esiintymistä jo etukäteen.

Tulevaan kysyntään on mahdollista varautua toisaalta myös varmuusvarastojen avulla. Riittävän suurten varmuusvarastojen avulla pystytään kysyntä täyttämään suoraan varastosta ja varastotason laskiessa riittävän alas täydennetään varmuusvarastoa. Varmuusvarastot sopivat hyvin tasaisen kysynnän tuotteille, jotka kuluva säännöllisesti. Va-

rastonhallinta automatisoituu varmuusvarastojen avulla. Epäsäännöllisen kysynnän tuotteille varmuusvarastot eivät kuitenkaan sovellu yhtä hyvin. Tuotteet makaavat käyttämättöminä varastossa pitkiä aikoja, jolloin pääomaa on sitoutuneena. Toisaalta, jos kysynnän vaihtelu on suurta, pitää varmuusvarastojen olla suuret ja riski puutteista kasvaa. Epäsäännöllisen kysynnän tuotteille ennustamisen rooli on merkittävä, jotta liian suuria varmuusvarastoja ei tarvitse ylläpitää ja toisaalta, että kysyntään pystytään vastaamaan sen ilmaantuessa.

## 2.5.2 Varastonimikkeiden kysyntämallit

Varastonimikkeiden kysyntä on usein hyvinkin erilaista. Joitakin nimikkeitä voi kulua säännöllisesti, kun taas toisia silloin tällöin epäsäännöllisen kokoisissa tilauserissä. Varastonimikkeiden kategorisointia ennustamisen kannalta ei kuitenkaan ole tutkittu kirjallisuudessa kovinkaan paljon (Boylan et al. 2008). Williams (1984) kategorisoi ensimmäisenä tilastollisesti erilaisia kysyntämalleja varastonimikkeille ennustamisen näkökulmasta. Hänen mukaansa ennustusmallin ja varastonhallintametodin valinta riippuu kysynnän jakaumasta. Tasaisen kysynnän tuotteiden hallintaa on tutkittu pitkään, mutta nämä lainalaisuudet eivät sovellu tuotteisiin, joilla on satunnainen tai paakkuinen kysyntä. (Williams 1984.)

Yleinen käytäntö on, että nimikkeiden kysynnän kategorisoinnin jälkeen valitaan menetelmä ennustamiselle ja optimoidaan ennustusten parametrit. Vaihtoehtoisesti ennustuksille voitaisiin suoraan vertailla teoreettisesti määritettyjen virhemittareiden avulla. Täten on mahdollista havaita erityisen hyvin käyttäytyviä alueita, joiden avulla määritellään nimikkeiden kysyntämallit. (Syntetos & Boylan 2005.) Jälkimmäistä vaihtoehtoa kategorisoinnin tekemiseksi on tutkittu huomattavasti, ja se on noussut tärkeäksi keinoksi sekä ennustamisen että varastonhallinnan kannalta (Heinecke et al. 2013).

Williams (1984) määritti neljä eri kategoriaa, joihin varastonimikkeet pystytään luokittelemaan: tasainen, hidas, satunnainen ja erittäin satunnainen kysyntä. Williams kategorisoi nimikkeet niiden varianssin avulla tarkastelemalla erikseen kysyntöjen välistä aikaa, jolloin ei ole kysyntää sekä kysynnällisten aikajaksojen vaihtelua. Tasaisessa kysynnässä tilauksia syntyy tasaisesti eikä tilauksettomia aikajaksoja juurikaan ole. Hitaassa kysynnässä on paljon aikajaksoja jolloin ei ole kysyntää, mutta kysyntöjen vaihtelu on vähäistä. Satunnaisessa kysynnässä sekä kysynnän esiintyminen että kysynnän tason vaihtelu ovat epäsäännöllisiä, mutta aikajaksot ovat vakioita. Erittäin satunnaisessa kysynnässä aikajaksot ovat tämän lisäksi epäsäännöllisiä.

Eaves ja Kingsman (2004) jatkoivat Williamsin jaottelua huomaten, ettei se kuvannut riittävän tarkasti eri kysyntämalleja. He jaottelivat kysyntämallit tasaiseen, epäsäännölliseen, hitaaseen, heikosti ajoittaiseen ja erittäin ajoittaiseen kysyntään. Ero Williamsin (1984) teoriaan on tasaisen kysynnän jakaminen tasaiseen ja epäsäännölliseen kysyntään. Eavesin ja Kingsmanin mukaan tasaisesti esiintyvä kysyntä, jolla on kuitenkin paljon vaihtelua tilauksien kokojen osalta, on epäsäännöllistä kysyntää. Williamsin ja Eaves & Kingsmanin teoriat lähtevät siltä pohjalta, että ensin kategorisoidaan nimikkeet kysynnän perusteella, jonka jälkeen valitaan ennustemallit ja varastonhallinnan keinot.

Syntetos et al. (2005) taas jatkoivat kategorisointia siltä kantilta, että ensin vertaillaan vaihtoehtoisia ennustusmenetelmiä, joiden perusteella nimikkeet jaotellaan. Heidän mukaansa kysyntämallit ovat tasainen, epävaka, ajoittainen ja paakkuinen kysyntä. Vertailussa he käyttivät hyödyksi variaatiokerrointa  $CV^2$ , jolla mitataan kysynnän suuruuden vaihtelua, sekä p-arvoa, joka tarkoittaa keskimääräistä kahden kysynnän välistä aikaa. Eri menetelmien testaamisen jälkeen he määrittivät katkaisuarvot näille mittareille, joiden perusteella nimikkeet jaoteltiin. (Syntetos et al. 2005.)

Taulukossa 1 on esitettyä tiivistetysti eri tilastolliset kategorisoinnit. Tässä on pyritty havainnollistamaan kategorisoinnissa käytetyt parametrit ja toisaalta yhtäläisyydet eri kategorisointien välillä.

**Taulukko 1:** Nimikkeistön tilastollinen kategorisointi

Kysynnän ominaisuudet			Kysynnän kategorisointi		
Kysynnän vaihtelu	Kys. esiintymisen vaihtelu	Aikajaksojen tasaisuus	Williams (1984)	Eaves & Kingsman (2004)	Syntetos et al. (2005)
Matala	Matala		Tasainen	Tasainen	Tasainen
Matala	Korkea			Epäsäännöllinen	Ajoittainen
Korkea	Matala		Hidas	Hidas	Epävaka
Korkea	Korkea	Matala	Satunnainen	Heikosti ajoittainen	Paakkuinen
Korkea	Korkea	Korkea	Erittäin satunnainen	Erittäin ajoittainen	

Nimikkeistön kategorisoinnin tarkoitus on löytää parhaimmat ennustusmallit jokaiselle kategorialle (Boylan et al. 2008). Varastoissa voi olla jopa tuhansia nimikkeitä, joita seurataan ja pyritään hallitsemaan. On lähes mahdotonta sovittaa erillisiä malleja jokaiseen nimikkeeseen, jolloin nimikkeistön kategorisoinnista on hyötyä. (Chatfield 2000.) Tässä tutkimuksessa hyödynnetään pääsääntöisesti lähestymistapaa, jossa vertaillaan eri mal-

leja dataan, minkä jälkeen kategorisoidaan nimikkeet eri luokkiin. Toisaalta myös aikaisempien tutkimusten ehdottamia ennustusmallien sopivuutta tietyn tyyppisiin nimikkeisiin hyödynnetään lähtökohtana.

Edellä kuvattujen metodien lisäksi kategorisoimisessa voidaan hyödyntää myös muita menetelmiä. Esimerkiksi yleinen käytäntö on ABC-jaottelun käyttäminen. Tässä mallissa nimikkeet jaotellaan kolmeen eri kategoriaan niiden kysyntämallin mukaan. A-ryhmään kuuluvat nopeasti liikkuvat tuotteet, joita on vain vähän. B-ryhmään taas seuraavaksi aktiivisimpia nimikkeitä, ja C-ryhmä on hitaasti liikkuvat. Varastohallinnan kannalta C-ryhmä on ongelmallisin ja tarvitsee huomiota enemmän kuin muiden ryhmien tuotteet. (Müller 2011.) Nimikkeistön kategorisoinnissa voidaan tilastollisen menetelmän lisäksi hyödyntää myös inhimillisiä lähteitä. Tämän lisäksi on paljon erilaisia tilastollisia menetelmiä, kuten päätöspuu, rykelmäanalyysit, optimointitekniikat tai geneettiset algoritmit. (van Kampen et al. 2012.)

## 2.6 Ennustamisen eri menetelmät

Ennustamiseen on kaksi yleistä lähestymistapaa, kvalitatiivinen ja kvantitatiivinen. Ennustamisen menetelmät taas voidaan karkeasti jakaa kolmeen eri kategoriaan. Chatfieldin (2000) mukaan nämä ovat:

1. Kvalitatiivinen ennustaminen
2. Aikasarjaennustaminen
3. Monimuuttujaennustaminen

Kvalitatiivinen ennustaminen tarkoittaa subjektiivisten tietolähteiden hyödyntämistä. Tällaisia lähteitä ovat esimerkiksi asiakaskyselyt, myyntihenkilöstö, johtajat ja päättäjät sekä asiantuntijat. Usein kvalitatiivinen ennustaminen tarjoaa oivalluksia, joita ei muuten olisi saatavilla. (Stevenson 2014, p.82.) Kvalitatiivista ennustamista hyödynnetään usein myös tilanteissa, joissa ei ole historiadataa saatavilla. Myös esimerkiksi uusien tuotteiden kohdalla ennustamiseen usein tarvitaan kvalitatiivisia menetelmiä tai tiedonlähteitä. Toisaalta saattaa olla myös tilanteita, joissa ulkopuoliset olosuhteet kuten muuttunut kilpailukenttä tai muutokset jakelumalleissa tekevät ennusteista epätarkkoja, jos seurataan vain historiadataa. (Mentzer et al. 2007.)

Aikasarjaennustaminen perustuu historiadan hyödyntämiseen tulevaisuuden ennakoimisessa (Stevenson 2014, p.82; Kolassa & Siemsen 2014, p.33) Aikasarja tarkoittaa sarjaa saman tyyppisistä mittauksista säännöllisin aikavälein mitattuina. Oletus on, että

aikaisemmat aikasarjat sisältävät informaatiota tulevaisuuden samanlaisesta sarjasta. (Kolassa & Siemsen 2014, p.33.) Aikasarjaennustaminen perustuu neljään eri toistuvaan kaavaan: trendi, kausivaihtelu, taso ja melu. Aikasarjaennustaminen on usein yksinkertainen ja edullinen käyttää eikä tarvitse hirveästi tietovarastokapasiteettia. Aikasarjaennustamista hyödynnetään yleisesti lyhyen aikavälin ennustamiseen ja se reagoi nopeasti muutoksiin. (Mentzer et al. 2007.)

Monimuuttujaennustaminen pohjautuu useamman selittävän muuttujan hyödyntämiseen kysynnän ennakoimisessa. Kysynnän voidaan nähdä olevan riippuvainen tietyistä tekijöistä, joiden analysoiminen parantaa ennustusten tarkkuutta. Tällaisia tekijöitä voivat olla esimerkiksi hinnoittelu, markkinointikampanjat ja tuotteen ominaisuudet. (Stevenson 2014, p.82.) Monimuuttujaisissa ennustusmalleissa yhdistetään tekijöiden vaikutukset malliin. Aikasarjaennustamisessa mallit usein hyödyntävät tiettyä matemaattista kaavaa. Monimuuttujaisessa ennustusmallissa yhdistetään useampia kaavoja, jos muuttujat ovat yhteisesti riippuvaisia.

Ennustamisessa voidaan hyödyntää yhdistelmiä näistä kolmesta eri menetelmästä. Yleistä on esimerkiksi käyttää kvantitatiivista aika-sarjaennustetta, jota täydennetään ulkoisella informaatiolla. Kvalitatiivista informaatiota on usein erittäin hankala ilmaista matemaattisessa mallissa, mikä johtaa useamman eri menetelmän saman aikaiseen käyttöön. (Chatfield 2000.) Kvalitatiiviset mallit toimivat usein lähtökohtana yritysten ennustamisessa, kun asiantuntijat arvioivat tulevaisuutta omien kokemusten ja asiantuntijuiden avulla. Aikasarjaennustamista taas hyödynnetään usein tilanteissa, joissa ennustettavien tuotteiden tai tekijöiden määrä ei ole hallittavissa pelkästään inhimillisten menetelmien avulla.

## **2.7 Kvalitatiiviset menetelmät**

Kaikki ennustusmallit eivät perustu täsmällisiin tilastollisiin tekniikoihin. Joissain tapauksissa hyvin informoidut harkinnalliset päätökset voivat tarjota tarkimmat ennusteet. Tällaisia voivat olla esimerkiksi tilanteet, joissa sisäpiiri tietää yrityksestä sellaista, mitä ei ole muille saatavilla. (Hanke et al. 2001, p.481.) Kun puhutaan yksilöiden tai ryhmien mielipiteisiin ja kokemuksiin perustuvasta ennustamisesta, tarkoitetaan kvalitatiivista eli toisin sanoen harkinnallista ennustamista. Tällaiset ennustusmenetelmät sisältävät muun muassa mielipiteitä, aavistuksia, kokemuksia ja uskomuksia. (Sanders 2015, p.65.)

Harkinnalliset päätökset ovat olennaisia komponentteja kaikissa ennustustekniikoissa. Harkintaa käytetään esimerkiksi, kun päätetään, mitä dataa ennustuksessa hyödynne-

tään, sopivan mallin valinnassa ja ennusteen tulosten esittämisessä. Tämän lisäksi harkinnalla voi olla merkittävä rooli itse analysointivaiheessa. (Hanke et al. 2001, p.481.) Kvalitatiivisia menetelmiä voidaan käyttää myös ilman tilastollista dataa. Esimerkiksi uusien tuotteiden kohdalla ei ole laisinkaan aikaisempaa kysyntäinformaatiota, jolloin ennustaminen on aloitettava kvalitatiivisella menetelmällä. (Mentzer et al. 2007.)

Kvalitatiivisia menetelmiä hyödynnetään tyypillisesti osana pitkän aikavälin ennustamista sekä yritystason ennustamisessa. Tämän lisäksi niitä käytetään parantamaan kvantitatiivisten ennustusmallien tarkkuutta. Tätä niin kutsuttua harkinnallista oikaisua käytetään lähinnä lyhyen aikavälin ennusteiden parantamisessa. (Mentzer et al. 2007.) Kvalitatiiviset menetelmät ovat hyvin yleisiä yrityksissä. Erään tutkimuksen mukaan jopa 67 prosenttia yrityksistä käyttävät ensisijaisina ennustusmenetelminä kvalitatiivisia metodeita. (Sanders 2015, p.53.) Toisen viimeaikaisen tutkimuksen mukaan 16 prosenttia käyttää ainoastaan kvalitatiivisia, 29 prosenttia vain kvantitatiivisia ja 55 prosenttia molempia yhdessä (Fildes, Robert & Petropoulos 2015). Toisaalta Boulaksil ja Franses (2009) päätyivät tutkimuksessaan siihen, että jopa yli 50 prosenttia ennusteiden tekijöistä eivät luota yrityksen tilastollisiin menetelmiin tehdessään ennustuksia. Kaiken kaikkiaan voidaan todeta, että kvalitatiiviset menetelmät ovat merkittävässä roolissa osana yritysten ennustusprosesseja.

### **2.7.1 Kvalitatiivisten menetelmien hyvät ja huonot puolet**

Kvalitatiivisten menetelmien käyttämiselle on olemassa selkeät syyt. Ensinnäkin päätöksentekijät näkevät tilastolliset menetelmät nk. mustana laatikkona, jonka sisällöstä heillä ei ole tarkkaa tietoa. Tietämättömyys menetelmien käyttäytymisestä ja logiikasta aiheuttaa sen, ettei niiden käyttäminen tunnu mielekkäältä. Päätöksentekijät tuntevat olonsa mukavammaksi, kun he käyttävät prosesseja, jotka he tuntevat ja ymmärtävät. Tämän lisäksi kvalitatiiviset menetelmät antavat käyttäjilleen omistajuuden tunteen, että he ovat osallistuneet ennusteen luomiseen. Kvalitatiiviset ennusteet on usein myös helpompia selittää sidosryhmille kuten asiakkaille tai johtoryhmälle. (Sanders 2015, p.53.) Olennainen syy kvalitatiivisten menetelmien käyttämiselle on historiallisen datan puuttuminen, ja toisaalta myös datan paikkansapitävyys analyytikoiden mielestä. Äärimmäisessä tapauksessa voidaan nähdä, että historiadata ei ole relevanttia tulevaisuuden kannalta, mikä johtaa kvalitatiivisten menetelmien käyttöön. (Hanke et al. 2001, pp.481.482.)

Kvalitatiivisilla menetelmillä on useita hyviä puolia. Sandersin (2015) mukaan suurimmat vahvuudet ovat: 1) nopea reaktiivisuus viimeisimpiin muutoksiin ympäristössä, 2) sisältää sisäpiiri- ja hiljaista tietoa, jota on vaikea mitallistaa ja 3) kompensoi hyvin yksittäiset

tai epätavalliset tapahtumat. Kvalitatiivisia ennusteita tekevät usein ihmiset, jotka työskentelevät samassa työympäristössä. Nämä ihmiset pitävät hallussaan asiantuntevuutta ja suhteita toimialallaan, joten he saavat tietoa mahdollisista merkittävistä muutoksista tai tapahtumista (Sanders 2015, pp.67-68.) Kvalitatiivisten menetelmien etuna voidaan nähdä myös se, etteivät ne tarvitse juurikaan muodollista informaatiota. Kvalitatiiviset menetelmät ottavat hyvin huomioon avaintyöntekijöiden kokemukset ja tietämyksen. (Mentzer et al. 2007.)

Kvalitatiivisilla menetelmillä on myös heikkouksia ja mahdollisia uhkia epäonnistumiselle ja virheille. Heikkoudet voidaan jakaa ihmisten kognitiivisiin heikkouksiin sekä vinoutumiin. Kognitiivisia heikkouksia ovat muun muassa: 1) rajoitettu tarkkaavaisuus, 2) lyhyen aikavälin muisti ja 3) vaikeus ymmärtää syy-seuraussuhteita. Vinoutumia voivat aiheuttaa 1) johdonmukaisuuden puute, 2) optimismi, 3) toiveajattelu ja 4) poliittinen manipulaatio. Kvalitatiiviset ennustusmenetelmät ovat erittäin subjektiivisia ja haavoittuvaisia vinoutumille. Päätöksentekotilanne vaikuttaa ennusteen suuntaan ja johtajien tekemät ennusteet ovat tutkitusti osoittautuneet olevan liian optimistisia. Ennusteilla on usein vaikutuksia ennusteen tekijöille. Esimerkiksi, jos budjetointia tehdään ennusteisiin pohjautuen tai jos suorituskkyä mitataan ennusteisiin verraten, on täysin luonnollista, että ennusteiden luomisessa huomioidaan vaikutukset muihin toimintoihin. Täten ennusteet saavat vaikutteita niihin liittymättömistä asioista ja ovat jo valmiiksi vinoutuneita. (Sanders 2015, pp.67-69.)

## 2.7.2 Kvalitatiivisia menetelmiä

Tunnistettuja kvalitatiivisia ennustusmenetelmiä on useita erilaisia. Sandersin (2015) mukaan merkittävimmät menetelmät ovat johtotason mielipiteet, markkinatutkimukset ja Delphi-metodi. **Johtotason mielipiteitä** rakennetaan kollektiivisesti yhteisissä kokouksissa. Kyseinen metodi ei ole kovinkaan strukturoitu ja se riippuu paljolti ryhmän mielipiteistä ja keskustelusta. Kyseisen menetelmän etuna voidaan nähdä, että ryhmänä saadaan helpommin ja enemmän esille hiljaista tietoa. Tieto on myös usein hyvin ajantasaista. Menetelmä on kuitenkin haavoittuvainen vinoumille ja ryhmissä usein tietty henkilö saattaa dominoida liikaa, jolloin ennusteiden tarkkuus kärsii. (Sanders 2015, pp.70-71.) Johtotason mielipiteiden käyttäminen on hyödyllistä varsinkin silloin, kun ei ole saatavilla dataa tilastollisiin menetelmiin (Rowe & Wright 2001).

**Markkinatutkimukset** toimivat myös ennustamisen keinona. Niissä käytetään kyselyitä ja haastatteluja, joilla pyritään selvittämään asiakastarpeita, mieltymyksiä ja asiakkaiden

vieroksumia asioita. Markkinatutkimuksilla pyritään ennustamaan, mitä asiakkaat halua-  
vat, ja tämän avulla arvioimaan omien tuotteiden kysyntää. Markkinatutkimukset ovat  
usein hankalia toteuttaa ja yritykset käyttävätkin paljon ulkopuolisia yrityksiä markkina-  
tutkimusten teettämisessä. (Sanders 2015, pp.71-72.) Markkinatutkimuksia hyödynne-  
tään varsinkin uusien tuotteiden kohdalla, jolloin ennustaminen aloitetaan jo huomatta-  
vasti ennen tuotteen lanseeraamista. Markkinatutkimusten tarkoituksena on relevantin  
tiedon kerääminen asiakkailta, minkä pohjalta ennuste voidaan luoda. (Mas-Machuca et  
al. 2014.)

**Delphi-metodi** on laajasti käytetty ongelmanratkaisumalli, jota hyödynnetään myös en-  
nustamisessa. Delphi-metodissa hyödynnetään asiantuntijoista koostuvaa paneelia ja  
kyselyitä, joiden iteratiivisen luonteen avulla pyritään saamaan tarkin mahdollinen en-  
nuste. (Rowe & Wright 1999; Skulmoski et al. 2007; Hsu & Sandford 2007.) Delphi-me-  
todi perustuu ajatukseen, että tyypillisesti asiantuntijat eivät ole samaa mieltä kaikesta,  
mutta se mistä he ovat pääsääntöisesti yhtä mieltä tapahtuu todennäköisesti (Sanders  
2015). Delphi-metodin neljä avainominaisuutta ovat anonymiteetti, iterointi, kontrolloitu  
palaute ja tilastollinen yhdistäminen. Näiden avulla pyritään kasvattamaan menetelmän  
tarkkuutta ja objektiivisuutta. (Rowe & Wright 1999.)

Eräs laajasti hyödynnetty ennustusmenetelmä on **skenaariosuunnittelu**. Tässä meto-  
dissa nähdään, että tulevaisuudella voi olla useampia erilaisia skenaarioita. Tuntemalla  
nämä skenaariot voidaan selvittää, mitkä seikat ovat ennalta määrättyjä ja ennakoita-  
vissa ja mitkä epämääräisiä. Skenaarioiden avulla päätöksentekijöille syntyy tarkempi  
kuva tilanteesta ja toimintaympäristöstä. (Van Der Heijden 2000.) Skenaarioita hyödyn-  
netään moninaisissa tehtävissä osana päätöksentekoa. Skenaarioiden avulla hallitaan  
tilanteita, joissa on huomattavasti epävarmuutta ja paljon muuttujia sekä muutosnopeus  
on suuri. (Masini & Vasquez 2000.)

Kvalitatiivisten menetelmien hyödyntäminen osana ennustamisen prosessia on laajasti  
käytetty ja tunnistettu. Menetelmien hyödyntäminen sellaisenaan ennusteiden luomi-  
sessa on eräs vaihtoehto. Toinen merkittävä vaihtoehto on hyödyntää harkinnallisia me-  
netelmiä parantamaan tilastollisten ennusteiden tarkkuutta. **Harkinnallisilla oikaisuille**  
pystytään korjaamaan ja parantamaan tilastollisten menetelmien tarkkuutta (Lim &  
O'Connor 1995). Tilastolliset menetelmät pystyvät käsittelemään suuren määrän dataa  
nopeasti, kun taas kvalitatiivisesti voidaan tunnistaa poikkeavia tilanteita ja ulkoisia teki-  
jöitä, jotka vaikuttavat tulevaisuuteen. Erään tutkimuksen mukaan jopa yli 80 % ennus-  
teista oikaistaan yrityksissä kvalitatiivisesti. Suurimmalle osalle yrityksistä harkinnalliset  
oikaisut ovat ainoa käytännöllinen keino tärkeimpien tekijöiden huomioimiseksi osana  
ennustusprosessia. (Fildes, R. et al. 2009.)



## 2.8 Aikasarjaennustaminen

Aikasarjaennustaminen on osa kvantitatiivista ennustamista, jossa hyödynnetään matemaattisia malleja ja tilastollisia ohjelmistoja ennusteiden luomisessa. Ennustaminen perustuu historiadatan hyödyntämiseen tulevaisuuden ennakoimisessa. Tunnistamalla ja kokoamalla datan kaavoja sekä ilmaisemalla tilastollisia riippuvuuksia nykyisten ja edeltävien arvojen välillä voidaan projektoida vastaavat kaavat tulevaisuuteen. (Montgomery et al. 2015, p.5.) Aikasarja on joukko havaintoja mitattuna peräkkäin ajan kuluessa. Havainnot voidaan ottaa joko jatkuvasti tai tietyin aikavälein. Täten aikasarjat voidaan jakaa jatkuviin ja diskreetteihin sarjoihin. Diskreetti aikasarja voidaan muodostaa pääsääntöisesti kolmella tavalla: ottamalla otos tietyin aikavälein, keräämällä tietyn aikavälin arvot yhteen tai luonnollisen diskreetin jakauman avulla. (Chatfield 2000.)

Aikasarjaennustamisessa pyritään tunnistamaan toistuvia kaavoja, joiden avulla ennustustmallin valinta helpottuu ja ennustaminen tarkentuu. Tällaisia komponentteja ovat trendi, kausivaihtelu, taso ja melu (Kolassa & Siemsen 2014; Sanders 2015). **Trendi** edustaa datan taustalla piilevää kasvua tai laskua. Trendi muodostuu esimerkiksi muutuneen toimintaympäristön, tuotannon kasvun tai investointien seurauksena. Trendit ovat pitkän aikavälin muutoksia aikasarjassa, joita voidaan kuvata suoran linjan tai tasaisen käyrän avulla. (Hanke et al. 2001, pp.168-169.) Trendi voidaan kuvata pitkän aikavälin keskiarvon muutoksena. Haasteena on kuitenkin määrittää, mikä on pitkä aikaväli ja mikä on nykyinen keskiarvo. Trendiin vaikuttava pitkä aikaväli riippuu ainakin analysoitavan aikasarjan pituudesta. (Chatfield 2000.)

**Kausivaihtelu** viittaa ennakoitaviin ja toistuviin hetkellisiin muutoksiin aikasarjan tasossa. Kausivaihtelut voivat johtua ulkoisista säännöllisistä tekijöistä tai vastaavasti yrityksen sisäisistä toimenpiteistä. (Kolassa & Siemsen 2014, p.42.) Kausiluonteinen kaava toistuu säännöllisesti vuodesta toiseen. Valitun aikavälin pituudella on vaikutus koetun kausivaihtelun laajuuteen. Esimerkiksi vuosittaisen aikasarjan kohdalla ei ole nähtävissä vuoden aikana tapahtuvia kausivaihteluita kuten ei myöskään kuukausikohtaisessa tarkastelussa näy eri viikonpäivien kausivaihtelua. Kausivaihtelukomponentin analysoinnilla on suoria lyhyen aikavälin vaikutuksia ja se on tärkeää varsinkin alemman- ja keskijohdon toiminnoille. (Hanke et al. 2001, p.175.)

Aikasarjan **taso** tarkoittaa perusosaa, joka heijastaa aikasarjan lyhyen aikavälin keskiarvoa. Pieni heilahtelu pysyvän keskiarvon ympärillä on helpoin kaava ennustaa ja ennusteen tarkkuus on usein hyvä. (Sanders 2015, p.23.) Aikasarjan taso voidaan toisaalta myös tunnistaa muita kaavoja sisältävästä datasta. Kun aikasarjasta poistetaan trendi,

kausivaihtelu ja melu, jää jäljelle aikasarjan taso. Taso voidaan nähdä aikasarjan keski-kohtana minä hetkenä hyvänsä. (Kolassa & Siemsen 2014, p.43.) **Melu** tarkoittaa satunnaista vaihtelua aikasarjassa. Tämä epäsäännöllinen poikkeama aikasarjan tasosta voi johtua useasta eri syystä ja näiden syiden ennakoiminen on erityisen vaikeaa. (Stevenson 2014, p.86; Montgomery et al. 2015, p.18.) Toistuvat epätarkat ennusteet voivat johtua huonosta ennustamisen prosessista tai yksinkertaisesti liiallisesta melusta datassa. Melu onkin otettava huomioon arvioitaessa ennustusprosessia. (Kolassa & Siemsen 2014)

Eräs tunnistettava kaava datassa on näiden lisäksi **syklisyys**, joka on epäsäännöllistä vaihtelua datassa. Vaihtelu voi johtua esimerkiksi inflaatiosta tai tuotteen elinkaaresta. Ero syklisyyden ja kausivaihtelun välillä on se, että syklit eivät toteudu ennustettavassa tai toistuvassa pituudessa ja suuruusluokassa. (Sanders 2015, p.23.) Usein syklisyys on pidemmän aikavälin vaihtelua verrattuna kausivaihteluun (Chatfield 2000). Syklinen kaava on aaltomaista heilahtelua aikasarjan tason ympärillä (Hanke et al. 2001, p.63.)

Aikasarjaennustamisella ja tilastollisilla metodeilla ylipäätään on omat vahvuutensa ja heikkoutensa. Yleisesti tutkimukset ovat osoittaneet, että tilastolliset menetelmät ovat pääsääntöisesti tarkempia kuin kvalitatiiviset. Keskimäärin tilastolliset menetelmät parantavat ennustusten tarkkuutta 18 prosentilla. Kuitenkin alle 30 prosenttia yrityksistä hyödyntää tilastollisia menetelmiä ensisijaisena metodinaan. (Sanders 2015, p.53.) Tilastolliset menetelmät ovat pääsääntöisesti juuri niin hyviä kuin data niiden taustalla on. Jos data sisältää paljon virheitä, ei ennustuksetkaan ole kovin tarkkoja. (Caniato et al. 2011.)

Muita aikasarjaennustusten heikkouksia ovat 1) hitaus reagoida muuttuvaan ympäristöön, 2) hiljaisen tiedon integroimisen kalleus ja vaaditut ajalliset resurssit sekä 3) vaatimus teknisestä ymmärryksestä. Aikasarjaennustamisen vahvuuksiksi voidaan lukea 1) objektiivisuus, 2) johdonmukaisuus, 3) suuren datamäärän hyödyntäminen ja 4) useiden muuttujien ja monimutkaisten suhteiden huomioiminen. (Sanders 2015) Yksinkertaiset aikasarjamallit ovat yksinkertaisia toteuttaa, eivätkä vaadi resursseja kovinkaan paljon. Tällaiset metodit toimivat myös suhteellisen hyvin, jos ennustettavan datan sisältämä melu on alhainen. Epävarman kysynnän tapauksessa yksinkertaiset mallit eivät toimi yhtä hyvin, milloin tarvitaan monimutkaisempia malleja ja kattavampaa dataa. Tämä taas nostaa kustannuksia ja vaadittua aikaa ennustusprosessin luomiselle.

## 2.8.1 Yksinkertaiset mallit

Yksinkertaisia malleja on lukumäärällisesti huomattavasti vähemmän kuin monimutkaisia tilastollisia malleja. Mallien yksinkertaisuudella on kuitenkin tutkimusten mukaan positiivisia vaikutuksia. Päättäjien ja ennustusten käyttäjien on helpompi ymmärtää ja luottaa ennustuksiin. Toisaalta mallien liiallinen monimutkaisuus heikentää ennustusten tarkkuutta. (Green & Armstrong 2015.) Yksinkertaisia malleja, joita tässä työssä käsitellään, ovat naiivimalli (Stevenson 2014, pp.84-85), keskiarvomalli (Sanders 2015, pp.80-81) ja random walk (Chatfield 2000).

**Naiivimalli** tarkoittaa yksinkertaisesti, että tulevan aikavälin ennuste on sama kuin viimeisen aikavälin toteutunut arvo. Jos  $Y_t$  kuvaa seuraavan aikavälin ennustetta, voidaan naiivimalli esittää muodossa

$$Y_t = A_{t-1}, \quad (1)$$

jossa  $A_{t-1}$  on aiemman aikajakson toteutunut arvo. Vaikka naiivimalli saattaa vaikuttaa liian yksinkertaiselta, sen hyödyt ovat selvät. Se on käytännössä ilmainen, erittäin nopea ja helppo toteuttaa, kun dataa ei tarvitse analysoida. Naiivimalli on myös helppo ymmärtää. (Stevenson 2014, pp.84-85; Kolassa & Siemsen 2014, p.5.)

Naiivimalli toimii hyvin tasaisen kysynnän tuotteille, joiden kohdalla naiivimallin hyödyt korostuvat ennusteen tarkkuuden kasvaessa. Naiivimallia voidaan hyödyntää myös kausiluontoisen datan yhteydessä muuttamalla ennuste muotoon, jossa seuraavan aikajakson ennuste on edellisen kauden vastaavan aikajakson arvo. Esimerkiksi kuukausikohteisessa ennusteessa seuraavan kuukauden ennuste on edellisen vuoden saman kuukauden toteutunut arvo. Myös dataan, joka sisältää trendikomponentin, voidaan hyödyntää naiivimallia. (Stevenson 2014, pp.84-85.) Trendikorjattu naiivimalli voidaan esittää muodossa

$$Y_t = A_{t-1} + (A_{t-1} - A_{t-2}), \quad (2)$$

jossa  $Y_t$  on ennuste seuraavalle aikajaksolle ja  $A_t$  on toteutunut arvo aikajaksolla  $t$ . Kyseinen ennuste olettaa, että viimeisten kahden arvon välinen trendi jatkuu samanlaisena myös jatkossa.

**Random walk** –malli muistuttaa naiivimallia, mutta siinä ennustetta muutetaan satunnaismuuttujan avulla. Ennuste on esitettävissä muodossa

$$Y_t = A_{t-1} + Z_t, \quad (3)$$

jossa  $A_{t-1}$  on edellisen aikajakson toteutunut kysyntä ja  $Z_t$  on puhdas satunnaisprosessi tietyillä ehdoilla. (Chatfield 2000.) Satunnaisprosessi voi olla yksinkertaisesti satunnaisgeneraattori, joka tietyillä ehdoilla muodostaa pienen heilahtelun ennusteeseen. Random walk –malli perustuu ajatukseen, ettei seuraava toteutunut arvo voi olla koskaan täsmälleen sama kuin edellinen.

**Keskiarvomalli** on myös eräs yksinkertaisimmista malleista. Siinä otetaan koko datan arvoista keskiarvo, joka toimii sellaisenaan ennusteena. Keskiarvomalli voidaan esittää

$$Y_t = \frac{\sum_{i=1}^n A_{t-i}}{n}, \quad (4)$$

jossa  $Y_t$  seuraavan aikajakson ennuste,  $A_t$  on toteutunut kysyntä aikajaksolla  $t$  ja  $n$  on kaikkien aikajaksojen lukumäärä. Keskiarvomalli sopii sellaisen aikasarjan ennustamiseen, joka sisältää vain tasokomponentin. Esimerkiksi vakiintuneiden ja kypsien tuotteiden kysynnän ennustaminen onnistuu tällä mallilla. (Sanders 2015, pp.80-81.)

Yksinkertaisia malleja voidaan pitää lähtökohtana ennustamiselle. Kaikkien harkittujen ennustusmallien pitäisi toimia paremmin kuin nämä kyseiset yksinkertaiset mallit, muuten ei ole järkeä vaivautuakaan niiden käyttämiseen. (Sanders 2015, p.45.) Yksinkertaiset mallit reagoivat erittäin huonosti muutoksiin, ja harvoin ne toimivatkaan hyvin ainoana ennustusmetodeina. Yksinkertaiset mallit toimivat kuitenkin hyvänä vertailukohtana muiden mallien tarkkuutta arvioidessa.

## 2.8.2 Tasoittavat mallit

Hyvin usein data sisältää melua, joka johtuu useasta suhteellisen merkityksettömästä tekijästä. Tällaista vaihtelua on lähes mahdotonta ennustaa luotettavasti. Tasoittavat mallit pyrkivät tasoittamaan nämä vaihtelut ja poistamaan melun vaikutuksia. Kyseiset mallit ovat suhteellisen yksinkertaisia, mutta toimivat kuitenkin tehokkaasti. (Stevenson 2014, p.86.) Tasoittavia malleja ovat liukuvan keskiarvon malli (Evans 2008, p.198), painotettu liukuvan keskiarvon malli (Stevenson 2014, pp.88-89) ja eksponentiaalinen tasoitus (Hanke et al. 2001, pp.119-120).

**Liukuvan keskiarvon mallissa** ennuste lasketaan käyttämällä tiettyä määrää aikaisemmin toteutuneita arvoja. Näistä arvoista lasketaan keskiarvo, joka on seuraavan aikavälin ennuste. Liukuvan keskiarvon malli voidaan esittää muodossa

$$Y_t = \frac{A_{t-1} + A_{t-2} + \dots + A_{t-n}}{n}, \quad (5)$$

jossa  $Y_t$  on seuraavan aikajakson ennuste,  $A_t$  on toteutunut kysyntä aikajaksolla  $t$  ja  $n$  tarkoittaa valittujen aikajaksojen määrää. (Evans 2008, p.198.) Mallin liukuvuus tarkoittaa, että uusien todellisten arvojen ilmaantuessa ennustus päivitetään tiputtamalla vanhin arvo pois ja lisäämällä uusin keskiarvon laskentaan. Aikajakson määrän valinnassa pitää ottaa huomioon kysyntämalli ja ennusteen tarve reagoida muutoksiin. Mitä vähemmän aikajaksoja valitaan keskiarvon laskentaan sitä nopeammin malli reagoi muutoksiin. (Stevenson 2014, pp.87-88.)

**Painotettu liukuvan keskiarvon malli** eroaa edellisestä siinä mielessä, että keskiarvon laskemiseen käytetään puhtaiden toteutuneiden arvojen sijaan painotettuja arvoja. Tiettyjä arvoja painotetaan kertoimilla ennustustarkkuuden parantamiseksi. Malli voidaan esittää muodossa

$$Y_t = \alpha A_{t-1} + \beta A_{t-2} + \dots + \gamma A_{t-n}, \quad (6)$$

jossa  $Y_t$  on seuraavan aikajakson ennuste,  $A_t$  on toteutunut kysyntä aikajaksolla  $t$  ja  $\alpha$ ,  $\beta$  ja  $\gamma$  kuvaavat painotuskertoimia. Kertoimet voidaan valita mielivaltaisesti 0 ja 1 väliltä kuitenkin siten, että kertoimien yhteenlaskettu summa on yksi. Yleisesti korkeimmat painotuskertoimet annetaan viimeaikaisille arvoille. (Stevenson 2014, p.88.) Painotetulla liukuvalla keskiarvolla saadaan suhteellisen hyvin reagoiva ennustemalli, jolla pystytään antamaan painoarvoa tietyille datan aikajaksoille (Sanders 2015, p.82).

Painotettu liukuvan keskiarvon malli saadaan muutettua liukuvan keskiarvon malliksi valitsemalla jokaiselle aikajaksolle sama kerroin  $1/n$ . Pääsääntöisesti kertoimet voidaan valita harkintaa käyttäen analysoimalla historiadataa. Toinen vaihtoehto on vertailla eri kertoimilla saatuja ennustustarkkuuksia virheiden avulla (Stevenson 2014, p.89). Jotkin järjestelmät antavat myös mahdollisuuden optimoida kertoimet minimoimalla virheiden suuruudet.

Liukuvan keskiarvon malleissa ennuste perustuu toteutuneisiin arvoihin. **Eksponentiaalisessa tasoituksessa** ennuste muodostetaan sekä edellisen aikajakson ennusteesta että toteutuneesta arvosta. Tämän lisäksi hyödynnetään yhtä tasoituskerrointa. Malli voidaan esittää muodossa

$$Y_t = \alpha A_{t-1} + (1 - \alpha)Y_{t-1}, \quad (7)$$

jossa  $Y_t$  on ennuste aikajaksolle  $t$ ,  $A_t$  on toteutunut kysyntä aikajaksolla  $t$  ja  $\alpha$  on tasoituskerroin,  $A_{t-1}$  on edellisen aikajakson toteutunut arvo ja  $Y_{t-1}$  on edellisen aikajakson ennuste. Kriittinen tekijä eksponentiaalisessa tasoituksessa on tasoituskertoimen valinta. (Sanders 2015, pp.82-83.) Tasoituskertoimen valinnassa on pohjimmiltaan kyse

inhimillisestä harkinnasta tai testauksesta ja ennustusvirheen minimoimisesta. Tavoitteena on valita kerroin, joka tasoittaa melun vaikutukset, mutta huomioi kuitenkin oleellisesti muutosten vaikutukset kysynnän vaihteluun. (Stevenson 2014, pp.89-90.)

Yleensä tasoituskerroin vaihtelee arvojen 0,05 ja 0,5 välillä. Pientä arvoa käytetään, kun datajoukon keskiarvo on vakaa. Suurempaa arvoa käytetään, jos kysynnässä tapahtuu paljon vaihtelua. Toisin sanoen, mitä pienempi arvo on, sitä voimakkaampaa on tasoitus. Eksponentiaalista tasoitusta hyödynnetään laajasti. Syitä tähän ovat helppokäyttöisyys ja nopeus sekä mahdollisuus vaikuttaa ennustusmalliin tasoituskertoimen kautta. (Stevenson 2014, p.90.) Yleisesti eksponentiaalinen tasoitus sopii tasaisen kysynnän aikasarjoille. Se on todettu toimivan optimaalisesti melua sisältävän datan ennustamiseen. (Gardner Jr. 2006; Kolassa & Siemsen 2014, p.51.)

### 2.8.3 Trendikorjatut mallit

Yksinkertaiset sekä tasoittavat mallit soveltuvat pääsääntöisesti vakaan kysynnän aikasarjoihin, joissa ei ole merkittävää trendiä tai kausiluonteisuutta. Jos kysynnässä on selkeä trendi, nämä edellä mainitut mallit reagoivat viiveellä muutokseen (Sanders 2015, p.83). Eräs keino on käyttää trendikorjattua eksponentiaalista tasoitusta, jossa sisällytetään trendikomponentti aiemman luvun yhtälöön. Yksi yleisimmistä malleista on niin kutsuttu **Holt-Wintersin malli** (HW-malli). Trendin sisältävä aikasarja voidaan ennustaa käyttämällä kaksinkertaista eksponentiaalista tasoitusta (Stevenson 2014, p.95)

**Kaksinkertainen eksponentiaalinen tasoitus** sisältää kaksi eri komponenttia: eksponentiaalisen tasoituksen- ja trendikomponentin (Holt 2004). Eksponentiaalisen tasoituksen komponentti tarkoittaa käytännössä samaa kuin kaava (7) lisättynä trendikomponentilla. Kokonaisuudessaan kaksinkertainen eksponentiaalinen tasoitus voidaan esittää muodossa

$$Y_t = l_{t-1} + T_{t-1}, \quad (8)$$

jossa

$$l_{t-1} = \alpha A_{t-1} + (1 - \alpha)(l_{t-2} + T_{t-2}) \quad (9)$$

$$T_{t-1} = \beta(l_{t-1} - l_{t-2}) + (1 - \beta)T_{t-2}. \quad (10)$$

Yllä mainituissa kaavoissa:

$Y_t$  = ennuste seuraavalle aikajaksolle

$A_t$  = toteutunut kysyntä

$l_t$  = eksponentiaalisen tasoituksen komponentti

$T_t$  = trendikomponentti

$\alpha$  = tasoituskerroin tasokomponentille

$\beta$  = tasoituskerroin trendikomponentille.

Tätä kaksinkertaista eksponentiaalista tasoitusta kutsutaan myös **Holtin metodiksi**. (Gelper et al. 2010.)

Kaksinkertaisessa eksponentiaalisessa tasoituksessa kertoimet  $\alpha$  ja  $\beta$  valitaan mielivaltaisesti 0 ja 1 väliltä. Usein valinta tehdään kokeilemalla ja analysoimalla ennustusvirheitä. Trendikorjatulla eksponentiaalisella tasoituksella on kyky reagoida muutoksiin nopeasti ja toisaalta se poistaa melun aiheuttamaa epäsäännöllisyyttä. (Stevenson 2014, p.95.) Mallissa jokaisen aikajakson lopuksi päivitetään tasokomponentti sekä kasvun muutos trendikomponentin muodossa. Seuraavan aikajakson ennuste on näiden komponenttien yhteenlaskettu vaikutus. (Kalekar 2004.)

Jos aikasarjan trendi on lineaarinen, voidaan mallina hyödyntää myös **lineaarisen trendin yhtälöä**. Kasvun ollessa tasaista läpi aikasarjan voidaan yhtälön kulmakertoimen avulla mallintaa trendiä. Lineaarisen trendin malli voidaan kirjoittaa kaavana:

$$Y_t = a + bt, \quad (11)$$

jossa

$$a = \frac{\sum A_n - b \sum t}{n} \text{ ja} \quad (12)$$

$$b = \frac{n \sum t A_n - \sum t \sum A_n}{n \sum t^2 - (\sum t)^2}. \quad (13)$$

Kaavoissa  $a$  kuvastaa ennustetta  $Y_t$ , kun  $t = 0$ .  $b$  taas kuvaa lineaarisen trendin muutosta, kun  $A_t$  tarkoittaa toteutunutta kysyntää aikajaksolla  $t$  ja  $n$  tarkoittaa kaikkien aikajaksojen määrää. (Stevenson 2014, p.93.)

## 2.8.4 Kausiluonteiset mallit

Holt-Wintersin malli voidaan muokata sisältämään myös aikasarjan kausiluonteinen vaihtelu. Tätä mallia kutsutaan **kolminkertaiseksi eksponentiaaliseksi tasoitukseksi**. Mallissa lisätään tasoitettu kausiluonteinen komponentti kaksinkertaiseen eksponentiaaliseen tasoitukseen, joten se sisältää myös trendikomponentin. Kolminkertainen eksponentiaalinen tasoitus voidaan esittää muodossa

$$Y_t = l_{t-1} + T_{t-1} + S_{t-L}, \quad (14)$$

jossa

$$l_{t-1} = \alpha(A_{t-1} - S_{t-L}) + (1 - \alpha)(l_{t-2} + T_{t-2}) \quad (15)$$

$$T_{t-1} = \beta(l_{t-1} - l_{t-2}) + (1 - \beta)T_{t-2} \quad (16)$$

$$S_{t-L} = \gamma(A_{t-L} - l_{t-L}) + (1 - \gamma)S_{t-2L} . \quad (17)$$

Edellä mainituissa kaavoissa

$Y_t$  = ennuste seuraavalle aikajaksolle

$A_t$  = toteutunut kysyntä

$l_t$  = eksponentiaalisen tasoituksen komponentti

$T_t$  = trendikomponentti

$S_t$  = kausikomponentti

$\alpha$  = tasoituserroin tasokomponentille

$\beta$  = tasoituserroin trendikomponentille

$\gamma$  = tasoituserroin kausikomponentille

$L$  = kauden pituus (Gelper et al. 2010.).

Kolminkertaisen eksponentiaalisen tasoituksen kaava (14), ts. **Winterin malli**, sopii aikasarjaan, jonka kausikomponentin suuruus ei riipu trendistä. Toinen vaihtoehto on kerrannaisvaikutuksellinen malli, jossa positiivinen trendi kasvattaa kausivaihtelua ja toisaalta negatiivinen pienentää sitä. Tämä malli voidaan esittää muodossa

$$Y_t = (l_{t-1} + T_{t-1}) * S_{t-L}. \quad (18)$$

Tässä mallissa myös melu voidaan nähdä olevan kerrannaisesti riippuvainen trendistä, milloin positiivinen trendi kasvattaa myös satunnaista vaihtelua. (Montgomery et al. 2015, pp.277-280.)

Kausivaihtelun sisältävän aikasarjan ennustamisessa voidaan hyödyntää myös **kausi-luonteista painotetun liukuvan keskiarvon** mallia. Tässä mallissa hyödynnetään aiempien kausien toteutuneita arvoja, joiden avulla lasketaan nykyisen kauden vastaava ennuste. Kyseinen malli voidaan esittää muodossa

$$Y_t = \alpha A_{t-L} + \beta A_{t-2L} + \dots + \gamma A_{t-nL}, \quad (19)$$

jossa  $A_t$  on toteutunut kysyntä aikajaksolla  $t$  ja  $n$  on valittujen kausien määrä sekä  $L$  kauden pituus. Painotuskertoimet  $\alpha$ ,  $\beta$  ja  $\gamma$  ovat väliltä 0-1 ja niiden yhteenlaskettu summa on oltava 1. Kyseinen malli soveltuu kausiluonteisen aikasarjan ennustamiseen, eikä ota huomioon esimerkiksi trendin vaikutusta. Malli ei myöskään huomioi meneillään



olevan kauden muutoksia laisinkaan. Malli on kuitenkin yksinkertainen ja helppo toteuttaa.

## 2.8.5 Epäsäännöllisen kysynnän mallit

Epäsäännöllinen kysyntä jaotellaan usein omaksi ryhmäkseen ennustamisen suhteen. Eksponentiaalista tasoitusta ja liukuvaa keskiarvoa hyödynnetään moni paikoin epäsäännöllisen kysynnän ennustamiseen. (Syntetos & Boylan 2006.) Vaikka molemmat mallit ovat tutkitusti toimineet tyydyttävästi epäsäännöllisen kysynnän ennustamisessa, ne tasoittavat liiaksi ajoittaista ja satunnaista kysyntää. Normaali ennustusmenetelmä epäsäännölliseen aikasarjaan on kuitenkin Crostonin malli, jossa aikasarjat jaetaan ennustamisen näkökulmasta kahteen komponenttiin: kysynnän suuruuteen kysynnän toteutuessa ja kysyntöjen aikaväliin. (Syntetos & Boylan 2005.)

Epäsäännöllinen kysyntä koostuu aikajaksoista, jolloin ei ole kysyntää laisinkaan. Toisaalta usein kysynnän ilmaantuessa, sen suuruus saattaa vaihdella huomattavasti. Croston (1972) jaotteli nämä kaksi eri komponenttia toisistaan riippumattomiksi ja pyrki ennustamaan epäsäännöllistä kysyntää huomioimalla ne erillään. **Crostonin malli** voidaan esittää muodossa

jos  $A_{t-1} \neq 0$ ,

$$Z_t = \alpha A_{t-1} + (1 - \alpha)Z_{t-1} \quad (20)$$

$$V_t = \alpha q + (1 - \alpha)V_{t-1} \quad (21)$$

$$Y_t = \frac{Z_t}{V_t} \quad (22)$$

ja jos  $A_{t-1} = 0$ ,

$$Z_t = Z_{t-1} \quad (23)$$

$$V_t = V_{t-1} \quad (24)$$

$$Y_t = Y_{t-1}. \quad (25)$$

Edellä mainituissa kaavoissa

$Y_t$  = ennuste seuraavalle aikajaksolle

$A_t$  = toteutunut kysyntä

$Z_t$  = kysyntäkomponentti

$V_t$  = kysyntöjen aikavälikomponentti

$\alpha$  = tasoituserroin

$q$  = peräkkäisten kysynnättömien aikajaksojen määrä.

Tässä mallissa ennuste päivitetään aina kysynnän ilmaantuessa. Jos kysyntää ei ole, on ennuste edellisen aikajakson ennuste. Crostonin mallilla saavutetaan huomattavasti tarkempia ennustuksia kuin perinteisellä eksponentiaalisella tasoituksella epäsäännöllisen kysynnän tapauksissa. (Croston 1972.)

Vaikka Crostonin malli on yleisesti hyödynnetty ennustamisen metodi, on sillä heikkouksensa. Syntetos ja Boylan (2005) osoittivat tutkimuksessaan, että Crostonin malli on järjestelmällisesti vinoutunut. He oikaisivat Crostonin mallin, mikä poistaa vinoutuneisuuden. Kyseinen Syntetos ja Boylan Arvio (**SBA**) eroaa Crostonin mallista vain ennustefunktion (22) osalta. Ennustefunktio SBA:lle on

$$Y_t = \left(1 - \frac{\alpha}{2}\right) \frac{Z_t}{V_t}, \quad (26)$$

jossa  $Y_t$  on ennuste aikasarjalle  $t$ ,  $\alpha$  on tasoituskerroin,  $Z_t$  on kysyntäkomponentti ja  $V_t$  on kysyntöjen aikavälikomponentti. (Syntetos & Boylan 2005.)

Myös SBA:ta on oikaistu tarkemman ennusteen saamiseksi. Eräs vaihtoehto on käyttää kysyntä- ja aikavälikomponenteille eri tasoituskertoimia, jolloin malli monimutkaistuu, mutta tarkkuus paranee (Schultz 1987; Syntetos & Boylan 2005). SBA:sta on johdettu myös malli, joka arvioi kysynnättömien aikajaksojen välisen ajan sijaan kysynnättömien aikajaksojen esiintymistodennäköisyyttä. Mallissa ennuste päivitetään jokaisessa aikajaksossa. Teunterin, Syntetoksen ja Babain (2011) kehittänyt malli (**TSB**) on muotoa

jos  $A_{t-1} \neq 0$ ,

$$p_t = p_{t-1} + \beta(1 - p_{t-1}) \quad (27)$$

$$Z_t = Z_{t-1} + \alpha(A_{t-1} - Z_{t-1}) \quad (28)$$

$$Y_t = p_t * Z_t \quad (29)$$

ja jos  $A_{t-1} = 0$ ,

$$p_t = p_{t-1} + \beta(0 - p_{t-1}) \quad (30)$$

$$Z_t = Z_{t-1} \quad (31)$$

$$Y_t = p_t * Z_t. \quad (32)$$

TSB-mallissa

$Y_t$  = ennuste seuraavalle aikajaksolle

$A_t$  = toteutunut kysyntä

$Z_t$  = kysyntäkomponentti

$p_t$  = todennäköisyys kysynnän esiintymiselle

$\alpha, \beta$  = tasoituskerroin.

TSB-malli pyrkii SBA:ta ja Crostonin metodia paremmin ennakoimaan pitkiä kysynnättömiä jaksoja. Tämä tapahtuu päivittämällä todennäköisyyttä kysynnän ennustamiselle, joka lähenee arvoa 0 pitkien kysynnättömien jaksojen aikana. (Teunter et al. 2011.)

Epäsäännöllistä kysyntää voidaan ennustaa myös **Bootstrap-metodilla**. Tässä metodissa ennuste perustuu laajaan otantaan satunnaisesti valittuja aiemmin toteutuneita arvoja, jotka jitteroinnin avulla pyritään satunnaistamaan. Tämän lisäksi kysynnän esiintymistä ennustetaan esimerkiksi Markovin ketjun avulla. Bootstrap-metodi toimii seuraavasti

1. Datan keräys
2. Kysynnän esiintymisen todennäköisyyksien määrittäminen (Markovin ketju)
3. Kysyntä/ei kysyntää aikasarjan luominen Markovin ketjun avulla
4. Kysyntäjaksojen arvojen korvaaminen aikaisemmillä historiallisilla arvoilla
5. Kysyntäarvojen jitterointi
6. Kaikkien arvojen summaus ennustusjakson ajalta
7. Vaiheiden 3-6 toistaminen useaan kertaan
8. Syntyvän jakauman käyttäminen ennustettavan aikajakson ennusteena

Jitterointi suoritetaan kaavalla

$$A' = 1 + INT(A + Z\sqrt{A}), \quad (33)$$

jossa  $A'$  on jitteroitu kysyntä,  $A$  on satunnaisesti valittu toteutunut kysyntä ja  $Z$  on normaalijakautunut satunnaismuuttuja. (Willemain et al. 2004.) Markovin ketjussa määritetään todennäköisyydet mahdollisille tiloille aikaisemman tilan perusteella. Todennäköisyyksiä kuvataan matriisilla, joka esitetään muodossa

$$\begin{pmatrix} P_{1 \rightarrow 1} & P_{1 \rightarrow 2} \\ P_{2 \rightarrow 1} & P_{2 \rightarrow 2} \end{pmatrix}. \quad (34)$$

Edellä mainittu matriisi on nimeltään tilanmuutosmatriisi, joka kuvaa todennäköisyyttä tilan muutoksesta kahden eri tilan välillä. (Norris 1998.) Epäsäännöllisen kysynnän osalta nämä tilat ovat kysynnällinen tai kysynnätön aikajakso. Markovin ketjulla määritetään käytännössä todennäköisyys kysynnän esiintymiselle kysynnällisen tai kysynnättömän jakson jälkeen.

## 2.9 Monimuuttujaennustaminen

Esitellyt tilastolliset mallit pohjaavat ennusteensa ainoastaan aiempiin kysynnän määriin. Tällaisia malleja kutsutaan yksimuuttujamalleiksi. Kysyntä kuitenkin riippuu useista eri tekijöistä, kuten hinnasta, vastaavista tuotteista ja niiden ominaisuuksista sekä tuotannon tasosta. (Chatfield 2000). Menetelmiä, jotka huomioivat useampia tuotteiden ominaisuuksia, kutsutaan monimuuttujamalleiksi. Keskeistä tällaisissa menetelmissä on sellaisen mallin kehittäminen, joka summaa ennustavien muuttujien vaikutukset. Ensimmäinen analysoinnin metodi on nimeltään regressio. (Stevenson 2014, pp.100-101.)

Hyvin yleisesti käytetty monimuuttujamalli on **lineaarinen regressio**. Lineaarissa regressiossa mallinnetaan eri muuttujien välistä riippuvuutta toisiinsa seuraavan yhtälön avulla:

$$Y_c = a + b_1x_1 + b_2x_2 + \dots + b_nx_n, \quad (35)$$

jossa  $Y_c$  on ennustettava muuttuja,  $x$  on ennustava muuttuja,  $a$  on  $Y_c$ :n arvo kun  $x_1, x_2 \dots x_n = 0$ ,  $n$  tarkoittaa ennustettavien muuttujien määrää ja  $b$  tarkoittaa suoran kulmakerrointa. (Chatfield 2000; Stevenson 2014, p.101.) Tämän lisäksi malliin voidaan sisällyttää virhemuuttuja  $\varepsilon$ . Malli muistuttaa paljon lineaarisen trendin yhtälöä (11), mutta regression tapauksessa ei huomioida aikaa muuttujana laisinkaan. Yksinkertaisessa lineaarisessa regressiossa  $n = 1$ , mikä tarkoittaa vain yhden ennustavan muuttujan hyödyntämistä. (Montgomery et al. 2015, pp.107-108.)

Yksinkertaisen lineaarisen regression tapauksessa muuttujien välinen suhde on kuvattavissa suoran avulla. Kulmakertoimen ollessa positiivinen, muutokset toisessa muuttujassa vaikuttavat positiivisesti myös toiseen. Samoin käänteisesti negatiivisen kulmakertoimen tapauksessa. (Stevenson 2014) Eräs yleinen lineaarisen regression muoto on hinnan ja kysynnän välinen riippuvuus. Tässä mallissa  $Y_c$  kuvastaa kysyntää ja  $x_1$  hintaa. Yleisesti tällainen riippuvuus näkyy negatiivisena kulmakertoimena, mikä tarkoittaa, että hinnan kasvaessa kysyntä laskee. Täten kysyntää voidaan ennustaa analysoimalla hintakomponenttia.

Taulukossa 2 on summattu kaikki edellä esitellyt ennustamisen metodit.

Taulukko 2: Ennustemallien vertailu

Ennustemalli	Taso	Trendi	Kausi	Melu	Kaava
Harkinnalliset päätökset	x		x		Tunnistaa hyvin suuret poikkeavuudet
Naiivi	x				$Y_t = A_t - 1$
Random walk	x			x	$Y_t = A_{t-1} + Z_t$
Keskiarvo	x			x	$Y_t = \frac{\sum_{i=1}^n A_{t-i}}{n}$
Liukuva keskiarvo	x			x	$Y_t = \frac{A_{t-1} + A_{t-2} + \dots + A_{t-n}}{n}$
Painotettu liukuva	x	x		x	$Y_t = \alpha A_{t-1} + \beta A_{t-2} + \dots + \gamma A_{t-n}$
Eksponen. tasoitus	x	x		x	$Y_t = \alpha A_{t-1} + (1 - \alpha)Y_{t-1}$
Holt	x	x		x	$Y_t = l_{t-1} + T_{t-1}$ $l_{t-1} = \alpha A_{t-1} + (1 - \alpha)(l_{t-2} + T_{t-2})$ $T_{t-1} = \beta(l_{t-1} - l_{t-2}) + (1 - \beta)T_{t-2}$
Lineaarinen trendi	x	x			$Y_t = a + bt$ $a = \frac{\sum A_n - b \sum t}{n}$ $b = \frac{n \sum t A_n - \sum t \sum A_n}{n \sum t^2 - (\sum t)^2}$
Winter	x	x	x	x	$Y_t = l_{t-1} + T_{t-1} + S_{t-L}$ $l_{t-1} = \alpha(A_{t-1} - S_{t-L}) + (1 - \alpha)(l_{t-2} + T_{t-2})$ $T_{t-1} = \beta(l_{t-1} - l_{t-2}) + (1 - \beta)T_{t-2}$ $S_{t-L} = \gamma(A_{t-L} - l_{t-L}) + (1 - \gamma)S_{t-2L}$
Kausil. liukuva kesk.	x		x	x	$Y_t = \alpha A_{t-L} + \beta A_{t-2L} + \dots + \gamma A_{t-nL}$
Croston	x	x		x	$A_{t-1} \neq 0$ $A_{t-1} = 0$ $Y_t = \frac{Z_t}{V_t}$ $Y_t = Y_{t-1}$ $Z_t = \alpha A_{t-1} + (1 - \alpha)Z_{t-1}$ $Z_t = Z_{t-1}$ $V_t = \alpha q + (1 - \alpha)V_{t-1}$ $V_t = V_{t-1}$
SBA	x	x		x	$A_{t-1} \neq 0$ $A_{t-1} = 0$ $Y_t = \left(1 - \frac{\alpha}{2}\right) \frac{Z_t}{V_t}$ $Y_t = Y_{t-1}$ $Z_t = \alpha A_{t-1} + (1 - \alpha)Z_{t-1}$ $Z_t = Z_{t-1}$ $V_t = \alpha q + (1 - \alpha)V_{t-1}$ $V_t = V_{t-1}$

TSB	x	x	x	x	$A_{t-1} \neq 0$ $Y_t = p_t * Z_t$ $p_t = p_{t-1} + \beta(1 - p_{t-1})$ $Z_t = Z_{t-1} + \alpha(A_{t-1} - Z_{t-1})$	$A_{t-1} = 0$ $Y_t = p_t * Z_t$ $p_t = p_{t-1} + \beta(0 - p_{t-1})$ $Z_t = Z_{t-1}$
Bootstrap	x			x	$A' = 1 + INT(A + Z\sqrt{A})$ $\begin{pmatrix} P_{1 \rightarrow 1} & P_{1 \rightarrow 2} \\ P_{2 \rightarrow 1} & P_{2 \rightarrow 2} \end{pmatrix}$	
Lineaarinen reg.	x	x	x		$Y_c = a + b_1x_1 + b_2x_2 + \dots + b_nx_n,$	

Taulukon 2 mukaan ennustamisen mallit sopivat teoreettisesti sekä aiempien tutkimusten mukaan hyvin erilaisiin tilanteisiin ja aikasarjoihin. Taulukon perusteella on nähtävissä, että mallin monimutkaistuessa sen ominaisuudet paranevat. Toisaalta, kuten aiemmin todettiin, on ristiriitaista pitää monimutkaisia malleja täten tarkempina. Eri mallien vertailu käytännön tasolla tapahtuu ennustetta ja toteutunutta arvoa vertailemalla. Ennusteen ja toteutuneen arvon erotus on nimeltään ennusteen virhe.

## 2.10 Ennustamisen tarkkuus

Mikään edellä mainituista malleista ei ennusta täydellisesti, mikä johtaa ennusteen poikkeamiseen toteutuneesta arvosta. Vaikka malli ottaisi huomioon aikasarjan eri komponentit ja kysyntään vaikuttavat tekijät, liittyy kysyntään aina hieman satunnaista vaihtelua. Tätä ennusteen ja toteutuneen arvon poikkeamaa kutsutaan ennusteen virheeksi, ja se voidaan mitata ja esittää eri muodoissa. Ennustamisen tarkkuus on merkittävässä roolissa ennustemallin valinnassa yhdessä ennustamisen kustannusten kanssa. (Stevenson 2014, p.79.) Samoin kuin ennustamisen malleja on lukuisia erilaisia, on ennustamisen tarkkuuden arviointiin useita erilaisia vaihtoehtoja. Eri tutkimukset ja tutkijat suosittelevat eri malleja käytettäväksi, mutta usein vaihtoehdot eivät ole yleistettävissä ja saattavat olla harhaanjohtavia. Tämän lisäksi ne voivat vääristää ennustemallien valintaa. (Hyndman & Koehler 2006.)

**Ennusteen virhe** voidaan esittää muodossa

$$e_t = A_t - Y_t, \quad (36)$$

jossa  $e_t$  on ennusteen virhe,  $A_t$  on toteutunut kysyntä ja  $Y_t$  ennuste. Positiivinen virhe tarkoittaa, että ennuste on ollut liian alhainen ja negatiivinen että ennuste on liian suuri. (Stevenson 2014, p.80.) Absoluuttinen virhe on yksinkertainen tarkkuuden arvioinnin

keino yhden aikasarjan sisällä, kun arvioidaan esimerkiksi mallin kehittymistä ajan kuluessa. Metodi ei kuitenkaan sovellu esimerkiksi eri tuotteiden ennusteiden vertailuun, sillä se ei suhteuta virhettä kysynnän määrään.

Toinen yleisesti käytetty ennustamisen tarkkuuden arvioinnin työkalu on **keskimääräinen absoluuttinen virhe**. Tässä mallissa analysoidaan koko aikasarjan ennusteen tarkkuutta keskiarvallisesti. Kyseinen malli mittaa ennustevirheen vaihtelevuutta, ja se voidaan esittää

$$MAE = \frac{\sum_{t=1}^n |e_t|}{n}, \quad (37)$$

jossa  $e_t$  on virhe kuten kaavassa (36) ja  $n$  on kaikkien aikajaksojen määrä. (Montgomery et al. 2015, pp.65-66.) Toinen vastaavanlainen vaihtelevuutta mittaava malli on **keskimääräinen neliövirhe**. Tämä voidaan esittää

$$MSE = \frac{\sum_{t=1}^n e_t^2}{n-1}, \quad (38)$$

jossa  $e_t$  on virhe kuten kaavassa (36) ja  $n$  on kaikkien aikajaksojen määrä. Keskimääräinen neliövirhe painottaa virheitä niiden neliöllisten arvojen avulla. (Stevenson 2014, p.81.) Molemmat virheiden mittausmallit tarkastelevat ennusteiden ja toteutuneiden arvojen erotusta ainoastaan suuruuden kannalta. Mallit eivät ota kantaa erotuksen suuntaan, mikä ei paljasta ennusteen vinoutuneisuutta.

Keskimääräinen neliövirhe antaa virheiden arvoksi mittakaavallisesti suurempia arvoja kuin toteutuneet tai ennusteet ovat. Tämä voidaan kumota käyttämällä juurellista neliövirhettä, joka on yksinkertaisesti

$$RMSE = \sqrt{MSE}. \quad (39)$$

Molempia neliövirheitä on käytetty historiallisesti paljon niiden teoreettisen merkityksellisuuden tilastolliseen mallintamiseen nähden. Mallit ovat kuitenkin herkkiä reagoimaan suuriin melun poikkeavuuksiin. (Hyndman & Koehler 2006.) Tämä voidaan kuitenkin kääntää eduksi sellaisissa tilanteissa, joissa suuret erot ennusteen ja toteuman välillä ovat erityisen huonoja (Sanders 2015, p.42). Neliövirhemallit eivät sovellu eri aikasarjojen vertailuun, sillä ne ovat riippuvaisia mittakaavasta.

Joissain tilanteissa on hyödyllisempää laskea virheitä prosentteina absoluuttisten määrien sijaan. Yksinkertaisin tällainen malli on **keskimääräinen prosenttinvirhe**, joka huomioi virheen suunnan. Keskimääräistä prosenttinvirhettä kuvataan kaavalla

$$MPE = \frac{1}{n} \sum_{t=1}^n \left( \frac{e_t}{A_t} \right), \quad (40)$$

jossa  $n$  on kaikkien aikajaksojen määrä,  $A_t$  on toteutunut kysyntä ja  $e_t$  on absoluuttinen virhe. Tällä mallilla pystytään vertailemaan ennustusmallien vinoutuneisuutta, mutta se samalla voi antaa vääristyneen kuvan ennustusmallin toimivuudesta. MPE saattaa olla aikasarjalle pieni, vaikka todellinen ennusteiden heilahtelu on suurta, kun erimerkkiset virheet kumoavat toisensa. (Hanke et al. 2001, p.83.) Tämä korjaantuu käyttämällä **keskimääräistä absoluuttista prosenttivirhettä**. Tässä metodissa prosentuaalinen virhe lasketaan itseisarvollisesta absoluuttisesta virheestä. Metodi kaavana on

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|e_t|}{A_t}, \quad (41)$$

jossa  $n$  on kaikkien aikajaksojen määrä,  $A_t$  on toteutunut kysyntä ja  $e_t$  on absoluuttinen virhe. Tyypillisesti virhearvo kerrotaan vielä 100 %:lla, mikä helpottaa ennustusmallien vertailua. (Stevenson 2014, p.81.) Kyseinen metodi on hyödyllinen eri aikasarjojen vertailussa tietyllä ennustusmallilla, koska se ei ole riippuvainen mittakaavasta

Prosentuaalisilla virhemalleilla on myös heikkoutensa. Mallit eivät hyväksy aikajaksoa, jossa ei ole todellista kysyntää. Tämä johtaa virheeseen, jossa jakajana toimisi 0. Eräs vaihtoehto on lukea pois sellaiset aikasarjat kokonaan, mikä ei kuitenkaan ole mielekästä varastonhallinnan näkökulmasta. Toinen vaihtoehto on käyttää **symmetristä absoluuttista prosenttivirhettä**, jossa virheen jakajana toimii keskiarvo todellisesta kysynnästä ja ennusteesta. Tämä voidaan esittää muodossa

$$sMAPE = \frac{1}{n} \sum_{t=1}^n \frac{|e_t|}{\frac{A_t + Y_t}{2}}, \quad (42)$$

jossa  $n$  on kaikkien aikajaksojen määrä,  $A_t$  on toteutunut kysyntä,  $Y_t$  ennuste ja  $e_t$  on absoluuttinen virhe. (Kolassa & Siemsen 2014, pp.108-109.) Tämäkään malli ei toimi tilanteessa, jossa  $A_t = Y_t = 0$ . Eräs vaihtoehto tämän ohittamiseen on asettaa malliin ehto, jossa virheen ilmoitetaan olevan suoraan 0 % kyseisessä tilanteessa. Symmetrisen keskimääräisen absoluuttisen prosenttivirheen on kuitenkin osoitettu kärsivän epäsymmetrisyydestä tietyissä tilanteissa (Goodwin & Lawton 1999).

Eri ennustusmallien virheitä voidaan myös arvioida vertaamalla ennustusmallien virhettä tiettyyn benchmark malliin. Tämä malli voi olla esimerkiksi naiivimalli (Lawrence et al. 2000; Syntetos & Boylan 2005) tai vaihtoehtoisesti random walk –mallia (Armstrong, J. S. & Collopy 1992; Makridakis & Hibon 2000). Yksinkertaisin vertaileva malli on suhteellinen virhe, jossa vertailtavan ennustemallin virhe jaetaan benchmark-mallin virheellä. Koko aikasarjan virheiden keskiarvoistamiseen hyödyllinen malli on **keskimääräinen suhteellinen virhe**, joka voidaan esittää muodossa

$$MRAE = \frac{1}{n} \sum_{i=1}^n \left| \frac{e_{a,i}}{e_{b,i}} \right|. \quad (43)$$



Tässä mallissa  $e_a$  on vertailtavan mallin virhe,  $e_b$  on benchmark-mallin virhe ja  $n$  on kaikkien aikajaksojen määrä. (Davydenko & Fildes 2013.)

Suhteellisen virheen laskemisessa voidaan hyödyntää myös geometristä keskiarvoa, jossa hyödynnetään virheiden logaritmista keskiarvoa. **Geometrinen suhteellinen virhe** esitetään muodossa

$$GMRAE = \left( \prod_{i=1}^n \left( \frac{e_{a,i}}{e_{b,i}} \right) \right)^{1/n}, \quad (44)$$

jossa  $e_a$  on vertailtavan mallin virhe,  $e_b$  on benchmark-mallin virhe ja  $n$  on kaikkien aikajaksojen määrä. Suhteellisten virhemallien heikkoutena voidaan nähdä benchmark-mallin virheen mahdollisuus olla todella pieni. (Hyndman & Koehler 2006.) Suhteelliset virhemallit ovat myös rajoittuneita sen suhteen, että benchmark-mallin virhe ei saa olla 0. Naiivimallissa esimerkiksi jo kaksi kysynnätöntä aikajaksoa peräkkäin aiheuttaa ongelman, jossa nimittäjän arvo on 0.

Ennustemallien vertailu tapahtuu yksinkertaisesti vertaamalla eri mallien virhearvoja. Käytettävät virhemallit valitaan aikasarjan ominaisuuksien perusteella, mikä takaa ennustemallien valinnan toimivuuden. Yleistä on valita sekä useampia ennustemalleja että virhemalleja ja yrittää löytää se malli, joka tuottaa pienimmät virhearvot ennustusvirhemalleilla (Sanders 2015, pp.41-45). Lukuisista tutkimuksista kuitenkin selviää, että tulokset ovat usein ristiriitaisia, mikä näkyy pienimpien virhearvojen jakautumisena eri malleille (kts. esim. Makridakis & Hibon 2000; Hyndman & Koehler 2006). Tämä lisää painoarvoa mielekkäiden virhemallien valinnalle.

Kuten aiemmin todettiin, on esimerkiksi epäsäännöllisen kysynnän ennustevirheiden arviointiin mielekästä käyttää tiettyjä malleja. Kysynnän erilaisten mallien analysoinnin lisäksi on mielekästä pohtia ennustamisen tavoitteita ja ennustamisen prosessia yleisesti. Tärkeimpiä virhemallien valinnassa huomioitavia asioita ovat muun muassa

- mittakaava
- vaihtelun määrä
- poikkeavuudet
- virheiden keskiarvoistaminen.

Fokus tutkimuksissa on siirtynyt yksiköittämiin mittausmalleihin, jotta eri aikasarjojen mittakaavat eivät vääristä tuloksia. Esimerkiksi MAPE:a hyödynnetään laajasti. (Armstrong, J. S. & Collopy 1992.) Tässäkin on kuitenkin heikkoutensa, kuten että se painottaa enemmän liian suuria ennusteita liian pieniin verrattuna (Hyndman & Koehler 2006).

Suuren vaihtelun aikasarjojen ennustaminen on erityisen vaikeaa. Tästä johtuen virhemallit, jotka poistavat virheen suuruuden merkityksen, toimivat hyvin suuren vaihtelun aikasarjoille. (Armstrong, J. S. & Collopy 1992.) Eräs tällainen metodi on kahden ennustemallin välinen vertailu aikajaksoittain. Se malli, kumpi toimii tarkemmin aikajaksojen määrissä mitattuina, on parempi. (Syntetos & Boylan 2005.) Myös poikkeavuuksien suuruus ja määrä vaikuttavat virhemallien toimivuuteen, kuten aiemmin todettiin. Riippuen ennustamisen tavoitteista ja ennustustilanteesta, poikkeavuuksien tasoittaminen tai korostaminen virhemallissa on hyödyllistä. Poikkeavuuksien suuri määrä aiheuttaa ongelman myös virheiden keskiarvoistamisessa. Menetelmät, jotka summaavat koko aikasarjan ennustevirheet, vaikuttavat huonosti suoriutuvilta aikasarjoissa, joissa on suuria poikkeavuuksia (Armstrong, J. S. & Collopy 1992).

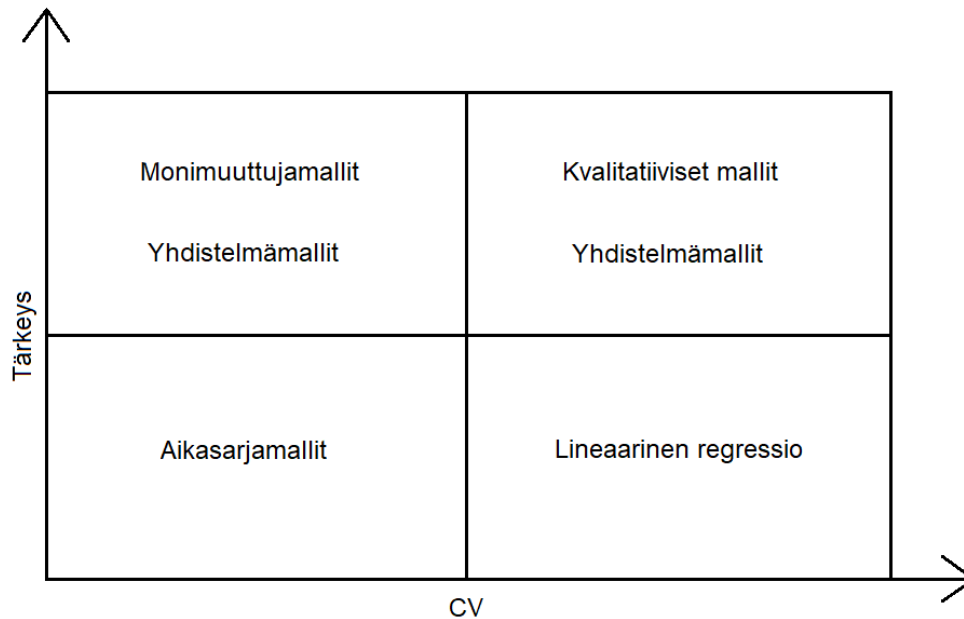
## 2.11 Ennustemallin valinta

Ennustemalli voidaan valita puhtaasti ennustevirheen analysoinnin avulla, mutta kuten aiemmin todettiin, voivat virhemallit tuottaa ristiriitaisia tuloksia. Virhemallien ohella voidaan käyttää myös muita valintakriteereitä. Eräs yleisesti hyödynnetty mallien valintatyökalu on kysynnän ominaisuuksien tarkastelu sen hajonnan ja esiintymismäärien perusteella (kts. esim. Boylan et al. 2008; Rego & Mesquita 2015). Myös ennustettavan tuotteen tärkeys on syytä huomioida ennustemallin valinnassa. Tuotteet, jotka ovat esimerkiksi helposti saatavilla tai niiden varastointiarvo on minimaalinen verrattuna muihin tuotteisiin, on helppo jättää pelkkien yksinkertaisten tilastollisten menetelmien ennustettavaksi. Toisaalta tuotteiden, jotka ovat tärkeitä asiakkaille tai tuotannolle ja joiden toimitusajat ovat pitkät, ennustamiseen on kiinnitettävä enemmän huomiota. (Sanders 2015, pp.109-110.)

Aikasarjojen hajontaa voidaan tutkia suoraan keskihajonnan avulla. Jos useamman aikasarjan hajontoja halutaan vertailla ja lajitella ennustusmallien valinnan kannalta, kannattaa keskihajontaa suhteuttaa esimerkiksi aikasarjan keskiarvoon. Sandersin (2015) tarjoama työkalu hajonnan määrittämiseen on variaatiokerroin

$$CV = \frac{\sigma}{\mu}, \quad (45)$$

jossa  $\sigma$  on keskihajonta ja  $\mu$  on keskiarvo aikasarjalle. Hän lajittelee variaatiokertoimen avulla tuotteiden kysynät kolmeen eri kategoriaan: vakaat ( $CV \leq 20 \%$ ), epävakaa ( $CV \geq 50 \%$ ) ja ennustamattomat ( $CV \geq 100 \%$ ). Sanders käyttää mallien valinnassa hyödyksi myös arviota tuotteiden tärkeydestä. Näistä valinnoista saadaan muodostettua karkea-luonteinen viitekehys, joka esitetään kuvassa 2.

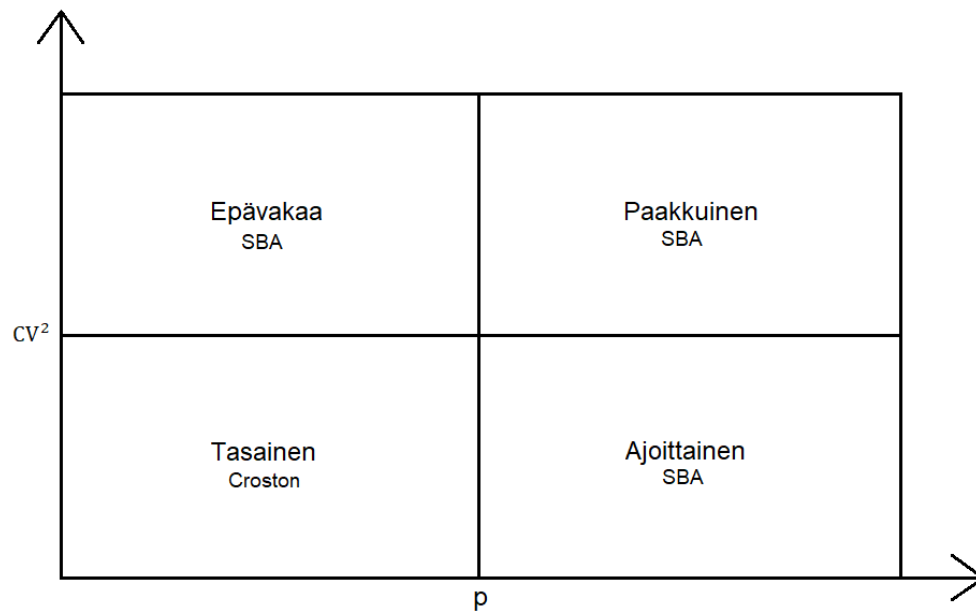


**Kuva 2.** Ennustemallien valinta (mukaillen Sanders 2015, p.110).

Kuvan 2 viitekehyksessä on jaoteltu ennustemallien valinta neljään eri kategoriaan aikasarjan hajonnan sekä tuotteen tärkeyden perusteella. Kyseinen viitekehys on karkean tason apuväline ennustusprosessin luomiselle.

Varastonhallinnan näkökulmasta yksittäinen ennustemalli ei riitä, vaan yhdistelmä erilaisia metodeita parantaa huomattavasti ennustustarkkuutta (Bon & Leng 2009). Varastoitavilla tuotteilla on usein hyvin erilaisia kysyntämalleja, jotka vaativat erilaisia ennustumalleja. Käyttämällä useita erilaisia ennustusmalleja pystytään varmistamaan mahdollisimman monelle tuotteelle optimaalisin ennustemalli. Ennustusjärjestelmät pystyvät usein määrittämään historiadatan perusteella optimaalisen mallin erikseen jokaiselle tuotteelle tarkastelemalla ennusteiden virheitä.

Aikasarjan hajontaa voidaan tutkia myös variaatiokertoimen neliön avulla. Tällöin suurta hajontaa keskiarvon suhteen korostetaan. Tätä käytetään varsinkin epäsäännöllisen kysynnän tapauksissa, kun tarkastelussa huomioidaan myös keskimääräinen aikaväli kahden kysynnän välillä. Boylanin et al. (2008) mukaan voidaan variaatiokertoimelle  $CV^2$  ja keskimääräiselle kysynnättömälle aikavälille  $p$  määrittää katkaisuarvot, joiden avulla ennustemallit valitaan. Tätä selvennetään kuvassa 3.



**Kuva 3.** Ennustemallin valinta kysynnän hajonnan ja esiintymisen avulla (mukaillen Syntetos et al. 2005).

Boylanin et al. (2008) tutkimuksen mukaan sopivat katkaisuarvot ovat  $CV^2 = 0,49$  ja  $p = 1,32$ . He myös määrittivät eri kysyntäkategorioiden sopivat ennustusmallit, joista parhaimmiksi osoittautuivat SBA ja Crostonin malli. Säännöllisen kysynnän tuotteille he valitsivat liukuvan keskiarvon ja eksponentiaalisen tasoituksen mallit.

### 3. ALKUTILANNEANALYYSI

Analyysin tavoitteena on selvittää varastohallinnan ja materiaalinimikkeiden nykytila sekä suurimmat ongelmat. Analyysin avulla selvitetään tutkimusta varten myös hankintaprosessien ja toimitusketjun rakenteet sekä näihin liittyvät ongelmat. Analyysissä selvitetään myös nykyisiä käytäntöjä varastonimikkeiden tulevan kysynnän ennakoimisessa ja ennustamisessa.

#### 3.1 Materiaalinimikkeiden varastohallinta alkuhetkellä

Lähes kaikki kohdeyrityksen varastonimikkeet ovat standardoituja tuotteita, joita käytetään projekteissa toistuvasti. Kohdeyrityksen näkökulmasta tuotteet ovat varastoon valmistettavia (MTS, Make-to-Stock), ja ne välitetään tuotannolle ja alihankkijoille sellaiseen varastosta. Yleisesti tällaisen varastointimalliin kuuluu, että tuotteet ovat saatavilla tilaushetkellä (Stevenson 2014, p.670). Kohdeyrityksen tapauksessa tuotteet luvataan kuitenkin asiakkaille seuraavaksi päiväksi. Osa tuotteista on kohdeyrityksen toimittajille uniikkeja, mikä tarkoittaa, että ne valmistetaan vain kyseisiin projekteihin. Tällaisissa tapauksissa lupaus seuraavan päivän toimitukselle on erittäin haasteellinen.

Kohdeyritys hankkii suurimman osan varastotuotteistaan muutamalta paikan päällä toimivalta jälleenmyyjältä. Nämä toimittajat hoitavat teoriassa omat varastonsa ja lupaavat toimituksen seuraavalle päivälle tilaushetkestä. Käytännössä varastomateriaalien hallinta toteutetaan kuitenkin yhteistyöllä ja yhteisillä järjestelmillä sekä prosesseilla. Jälleenmyyjät tilaavat tuotteita varastoonsa arvioidun kulutuksen mukaan ja sopimusten avulla on jaettu riskejä ylijäämävaraston osalta. Kohdeyritys on sitoutunut vastaamaan osaltaan käyttämättömien materiaalinimikkeiden hankinnasta, jos tuotteita ei saada myytyä eteenpäin. Tästä syystä kohdeyrityksen osallistuminen toimittajien kehittämiseen ja nimikkeiden tulevan kysynnän arvioimiseen on tärkeää myös kohdeyrityksen kannalta. Toisaalta projektien sujuvan toteutuksen ja projektin määräaikaan valmistumisen kannalta on tärkeää osallistua varastonimikkeiden toimitusketjun hallintaan ja kehittämiseen.

Paikan päällä toimivat jälleenmyyjät hoitavat omat varastonsa ja kohdeyritys tarjoaa järjestelmän tilausten tekemiselle. Jälleenmyyjät toimittavat varastotuotteensa suoraan joko käteisvarastojen tai suoratoimitusten kautta kohdeyrityksen alihankkijoille tai omalle tuotannolle. Muiden toimittajien kohdalla kohdeyritys hoitaa tuotteiden varastoinnin ja sen hallinnan tuotteiden tilaamisesta aina asiakkaille toimittamiseen asti. Näiden toimit-

tajien varastomateriaalit varastoidaan kohdeyrityksen keskusvarastolla, josta ne toimitetaan edelleen alihankkijoille ja tuotannolle. Karkeasti noin 80 % nimikkeistä on paikan päällä toimivien jälleenmyyjien vastuulla, ja loput 20 % hoidetaan kohdeyrityksen toimesta.

Alkuhetkellä varaston- ja nimikkeidenhallinnassa käytetään materiaalinhallinnanohjausjärjestelmää. Tällä järjestelmällä hoidetaan koko materiaalivirtaprosessi, johon kuuluvat esimerkiksi nimikkeiden tilaaminen, vastaanotto, lähetys, varastosaldon ylläpito ja nimikeluettelo. Järjestelmässä on tallennettuna kaikki standardoidut ja vakiintuneet nimikkeet, joita projekteissa tai kohdeyrityksen tukitoiminnoissa tarvitaan. Saapuvat tavaralähteykset kirjataan järjestelmään, ja sen kautta asiakkaat voivat tehdä tilauksia varastomateriaaleista. Myös tilausten luominen toimittajien suuntaan ja raportointi tapahtuvat kyseisen järjestelmän kautta.

Varastoitavilla nimikkeillä on useita eri tilauskokoja. Osa nimikkeistä tilataan kysynnän mukaan niissä määrissä kuin tilauksia keskusvarastolle saapuu. Osa nimikkeistä hallitaan varmuusvarastojen avulla, jolloin tilauskoot ovat vakiintuneempia. Tilauskoot vaihtelevat yksittäisistä tuotteista suuriin useiden tuhansien yksiköiden tilauksiin. Myös tilaushetket vaihtelevat nimikkeen ominaisuuksien ja kysynnän luonteen mukaan. Kohdeyrityksen itse hallinnoimat tuotteet tilataan vaihtelevasti kysynnän esiintyessä, hälytysrajan lähestyessä tai suuremmissa eräkoissa ennakoiden tulevaa kysyntää. Paikan päällä operoivien toimittajien hallitsemat tuotteet pääsääntöisesti hoidetaan varmuusvarastoilla tai nopeilla tilauksilla kysynnän esiintyessä.

Varastohallinnalla voidaan nähdä olevan muutama merkittävä ongelma alkuhetkellä. Eräs liittyy suureen varastonarvoon, kun varmuusvarastoissa tai liian suurten tilauskojen johdosta varastoissa on käyttämättömiä tavaroita. Tästä johtuen yrityksen pääomaa on sitoutuneena varastoon tarpeettoman paljon. Epävarmuus ja tietämättömyys tulevasta nimikkeiden kulutuksesta ja tarpeesta nostavat varmuusvarastojen tasoja sekä tilauskokoja. Käyttämätön varasto voi myös muuttua vanhentuneeksi esimerkiksi teknologisen kehityksen seurauksena. Varaston arvo on korkea myös projektien syklisyydestä johtuen. Useiden nimikeryhmien kohdalla on ominaista, että ne kuluvat pääsääntöisesti tietyssä projektin vaiheessa. Muun ajan nimikkeet sitovat pääomaa varastossa käyttämättöminä.

Merkittävän ongelman varastohallinnalle aiheuttavat myös muutokset suunnittelussa. Muutokset käytettävistä nimikkeistä voivat tehdä varastossa olevista nimikkeistä tarpeettomia, jolloin varastoarvo kasvaa ja menetetään pääomaa ylijäämäisen varaston takia.

Muutokset suunnittelussa myös hankaloittavat hankintaa ja tulevan kysynnän arvioimista. Uusien varastonimikkeiden luominen tai päätökset niiden hylkäämisestä hankaloittavat varastohallintaa huomattavasti. Epävarmuus käytettävistä nimikkeistä luo riskejä varmuusvarastoinnille sekä kohdeyrityksellä että paikan päällä toimivilla jälleenmyyjillä.

Uusien nimikkeiden luominen aiheuttaa myös ongelmia riittävän hyvän palveluasteen ylläpitämiselle. Tällaisten nimikkeiden kysyntää on hankala arvioida, kun aikaisempien projektien osalta nimikkeitä ei ole käytetty. Uudet nimikkeet aiheuttavat myös ylimääräistä työtä sopivien toimittajien järjestämisestä ja kilpailuttamisesta, laadun ja sopivien toimitusaikojen varmistamisesta sekä logistiikan ja varastoinnin hallinnasta. Uusilla nimikkeillä voi olla huomattavasti pidempi toimitusaika verrattuna jo vakiintuneisiin, varsinkin alkuvaiheessa ennen kuin toimittajat pystyvät sopeutumaan uusiin nimikkeisiin.

Muutokset suunnittelussa ja nimikkeissä aiheuttavat myös sekaannusta ja ylimääräistä työtä. Useat vaihtoehdot käytettävissä nimikkeissä lisäävät tarvittavan työn määrää, kun nimikkeiden soveltuvuus pitää selvittää sekä valita oikea nimike käyttötarkoituksen mukaan. Materiaalinimikkeiden vaihtaminen aiheuttaa myös sekaannuksia tuotannossa ja alihankkijoilla, kun jo aiemmin käytettyjä tuotteita ei olekaan enää saatavilla. Toisaalta jokainen projekti on erilainen ja vaatii tietyssä määrin erilaisia tuotteita. Myös jokaisen projektin suunnittelu eroaa tilaajan esittämien vaatimusten ja toiveiden mukaisesti.

Kohdeyrityksessä on suoritettu varastonimikkeistön harmonisointi yhdessä saman konsernin muiden tytäryhtiöiden kanssa vuonna 2018. Tästä johtuen nimikkeiden määrä kasvoi huomattavasti ja uusia nimikkeitä avattiin lisää merkittävä määrä. Näillä uusilla nimikkeillä ei ole kysyntähistoriaa kuin yhden vajaan projektin verran, mikä hankaloittaa kysynnän ennakoimista ja varastohallintaa. Harmonisoinnin seurauksena keskusvaraston palveluaste heikkeni rajusti varastonimikkeiden osalta ja paikan päällä toimivat jälleenmyyjät kohtasivat merkittäviä ongelmia uusien nimikkeiden hallinnassa.

Harmonisoinnin seurauksena syntyneet uudet nimikkeet ovat aiheuttaneet ongelmia kohdeyrityksessä, kun tuotanto ja suunnittelu sekä alihankkijat eivät tiedä riittävän tarkkaan, mitä standardoituja tuotteita on käytössä ja mitä niistä pitäisi käyttää. Uusien nimikkeiden takia on nimikkeistössä paljon päällekkäisyyksiä ja ristiriitaisuuksia, mikä tuottaa lisää työtä ja sekaannusta. Nimikkeistön muuttuminen on aiheuttanut myös ongelmia toimittajien osalta, kun heille ei ole pystytty arvioimaan tulevien projektien kulutusta riittävän tarkkaan. Toimittajat eivät ole pystyneet varautumaan kysyntään, joten nimikkeillä on ollut pitkät toimitusajat. Pitkät toimitusajat puolestaan haittaavat projektin aikataulussa pysymistä ja ajallaan valmistumista.

Siirtyminen vanhoista nimikkeistä osittain uusiin nimikkeisiin on aiheuttanut ongelmia paitsi toimittajille myös kohdeyrityksen tuotannolle ja alihankkijoille. Uusien tuotteiden käyttöönotossa ja vaihdossa on jouduttu tekemään huomattava määrä työtä ja käyttämään resursseja, jotta vaihto onnistuu. Epäselvyys ja ristiriidat nimikkeistössä ovat lisänneet työn määrää ja hankaloittaneet varastohallintaa. Harmonisoinnin seurauksena merkittävä osa käytettävistä nimikkeistä vaihtui samanaikaisesti, joka sekoitti sekä varastohallinnan että toimittajien prosesseja ja toimintaa.

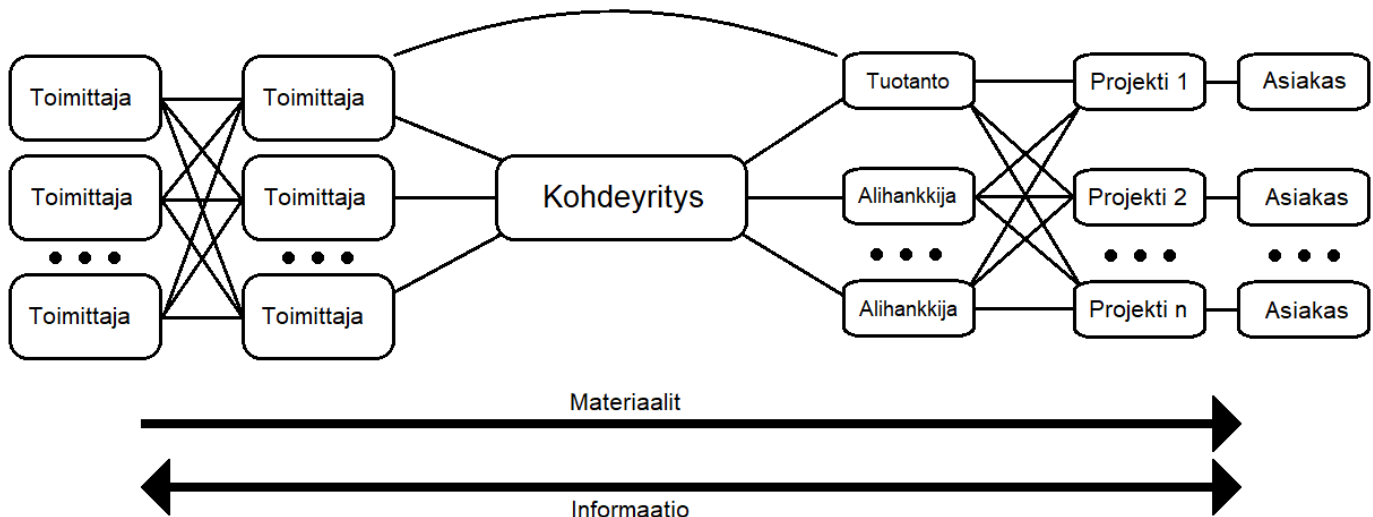
### **3.2 Kohdeyrityksen toimitusketju**

Kohdeyrityksen toimitusketju koostuu useammasta eri toimijasta ja tasosta. Projektiliiketoiminnalle ominaisesti toimitusketjut ovat eri projekteille omanlaisensa, mutta suurten toimijoiden osalta toimitusketjun voidaan nähdä olevan suhteellisen vakiintunut. Toimitusketju koostuu kaikista niistä aktiviteeteista, jotka liittyvät tuotteiden liikuttamiseen ja valmistukseen raaka-aineista aina lopullisiksi tuotteiksi asiakkaille asti (Seuring & Müller 2008). Tämän lisäksi toimitusketjuun liittyy olennaisesti myös informaation liikkuminen eri toimijoiden välillä. Suuret projektit vaativat huomattavan määrän niin toimittajia kuin yhteistyökumppaneita, joiden avulla projektien vieminen loppuun onnistuu ajallaan. Kohdeyritys johtaa toimitusketjua ja osallistuu myös projektien valmistukseen omalla panoksellaan.

Toimitusketju kokonaisuutena on hyvin laaja ja monitasoinen, johon kuuluu huomattava määrä eri toimijoita. Raaka-aine-, materiaali- ja komponenttitoimittajat muodostavat toimitusketjun alatasen, joka voidaan nähdä toisena merkittävä osana toimitusketjua. Toisen osan muodostavat projektien asiakkaat. Näiden lisäksi toimitusketjuun liittyvät oleellisesti niin kokonaistoimittajat kuin yhteistyökumppanit, jotka vaikuttavat ja osallistuvat projektien valmistukseen ja toimittamiseen loppuasiakkaille. Kohdeyritys johtaa toimitusketjua ja määrittelee projektien toteutukselle tavoitteet sekä rajoitteet. Yritys ottaa huomioon asiakkaiden toiveet ja vaatimukset sekä koordinoi toimitusketjun toimijoita tehokkaan ja toimivan ketjun muodostamiseksi.

Varastomateriaalien kannalta toimitusketju voidaan jakaa karkeasti kahteen osaan: toimittajat ja asiakkaat. Kuvassa 4 mallinnetaan varastomateriaalien toimitusketjua kohdeyrityksen näkökulmasta.





**Kuva 4.** Varastomateriaalien toimitusketju kohdeyrityksen näkökulmasta

Varastomateriaaleilla on lukuisia eri toimittajia ja valmistajia, jotka sopimusten mukaan toimittavat tarvittavat materiaalit projekteihin. Kohdeyritys hoitaa materiaalien ja komponenttien hankinnan sekä logistiikan järjestelyn. Materiaaleja käytetään suoraan kohdeyrityksen, alihankkijoiden ja yhteistyökumppaneiden toimesta projektien valmistamiseen ja osana lopputulosta. Osa varastomateriaaleista käytetään myös kohdeyrityksen sisäisiin toimintoihin. Tällaiset tuotteet eivät suoranaisesti ole osa projektin lopputulosta, vaan niitä hyödynnetään tuotannossa ja tukitoiminnoissa. Esimerkkeinä voidaan mainita toimitotarvikkeet, työkalut ja –koneet.

Kaikilla projekteilla on tietty tilaaja eli asiakas, joka on oleellinen osa toimitusketjua. Tilaaaja määrittää ehdot projektin lopputulokselle. Asiakkaan ja kohdeyrityksen välisten sopimusten mukaisesti päätetään materiaaleista ja komponenteista, jotka täyttävät asiakkaan ja toisaalta myös viranomaisten vaatimukset. Näiden ehtojen ja toiveiden avulla myös valitaan projektille sopivat toimittajat. Varastomateriaalien osalta toimittajia on lukuisia, mutta lukumäärällisesti suurimman osan tuotteista hoitaa muutama keskeinen toimittaja. Kohdeyrityksen välittömiä toimittajia esittää kuvan 4 toinen taso.

Kohdeyrityksen toimittajilla on omat toimitusketjunsä, jotka voivat koostua useista eri valmistajista, raaka-ainetoimittajista, jälleenmyyjistä ja välittäjistä. Tätä toimitusketjun osaa esittää kuvan 4 ensimmäinen taso. Toimittajien määrä tällä tasolla on moninkertainen verrattuna kohdeyrityksen välittömiin toimittajiin. On syytä myös huomioida, että osa ensimmäisen tason toimittajista voivat joidenkin varastomateriaalien osalta olla myös kohdeyrityksen välittömiä toimittajia. Kohdeyritys pääsääntöisesti johtaa vain välittömiä toimittajiaan, jotka taas hoitavat omat toimitusketjunsä.

Kohdeyritys toimittaa varastomateriaalit edelleen asiakkaille, joita tässä tapauksessa ovat oma tuotanto, alihankkijat, kokonaistoimittajat ja yhteistyökumppanit. Nämä toimijat voivat myös hankkia vastaavat materiaalit suoraan toimittajilta tai täysin eri toimittajilta ohittamalla kohdeyrityksen. Suurin osa nimikkeistä kuitenkin hankitaan kohdeyrityksen ja toimittajien välisten sopimusten kautta. Tuotanto ja alihankkijat käyttävät materiaaleja edelleen projekteihin ja pientä osaa tukitoimintoihin. Suurin osa näistä varastomateriaalien asiakkaista osallistuvat useamman kuin yhden projektin toteutukseen.

Varastomateriaalien toimitusketju päättyy loppuasiakkaaseen eli projektin tilaajaan. Usealla projektilla voi olla sama tilaaja, mutta projektit ovat kuitenkin aina yksilöllisiä. Tällöin myös toimitusketjut vaihtelevat materiaalien ja toimittajien sekä muiden toimijoiden osalta. Toimitusketjun ydinrakenne pysyy kuitenkin samanlaisena vakiintuneilla toimijoilla projektista toiseen. Kohdeyritys käyttää useita kokonaistoimittajia, jotka vastaavat tietyn projektin osakokonaisuuden toimittamisesta. Kokonaistoimittajat huolehtivat sopimusten ja asiakkaan ehtojen mukaisesti projektien eri osa-alueiden toteutuksesta ja toimittamisesta kohdeyritykselle.

Kuten kuvassa 4 esitetään, toimitusketjussa materiaalivirtaus liikkuu toimittajilta asiakkaiden suuntaan. Toimitusketjun toimittajien ja kohdeyrityksen välisen osan logistiikka hoidetaan toimittajista ja nimikkeistä riippuen joko kohdeyrityksen tai toimittajan puolesta. Kohdeyrityksen ja tuotannon sekä alihankkijoiden välinen logistiikka on ulkoistettu kolmannelle osapuolelle. Palautusten muodossa materiaalit liikkuvat myös pienissä määrin vastakkaiseen suuntaan, sekä viallisten tuotteiden että sopimusten mukaisesti hyvitettävien käyttämättömien materiaalien virtana.

Varastonimikkeiden toimitusketjussa informaatio liikkuu puolestaan molempiin suuntiin. Toimitusketjun alkuperäinen informaatioketju lähtee liikkeelle projektin tilaajasta, joka määrittelee tilaamalleen projektille ehdot ja tarpeet. Nämä puolestaan välittyvät kohdeyrityksen kautta koko toimitusketjuun. Kohdeyritys informoi sekä toimittajiaan että alihankkijoitaan tilaajan projektille asettamista ehdoista, jotka kulkeutuvat edelleen toimitusketjun alemmille tasoille. Informaatio liikkuu myös vastakkaiseen suuntaan toimitusketjussa. Esimerkiksi toimittajien toimitusvaikeuksista tai alihankkijoiden tuotantokeskeytyksistä tiedottaminen kohdeyritykselle ja edelleen projektin tilaajalle tietyissä tilanteissa vaativat informaation liikkumista toimitusketjun ”ylävirtaan”. Informaatio liikkuu säännöllisesti toimitusketjussa molempiin suuntiin esimerkiksi toiminnan kehittämisen ja monitoroinnin tapauksissa.

Yhteistyö toimitusketjun eri toimijoiden välillä on erityisen tärkeää sujuvan projektin toteutuksen kannalta. Useiden tutkimusten mukaan yhteistyön perusta koostuu keskinäisesti jaettavista hyödyistä, palkkioista ja riskeistä yhdessä informaation jakamisen kanssa (Stank et al. 1999; Barratt & Oliveira 2001). Informaation jakaminen ja kommunikointi koko toimitusketjun läpi on merkittävässä roolissa onnistuneessa ja tehokkaassa toimitusketjussa. Kommunikoinnin apuna voidaan käyttää integroitua teknologisia ratkaisuja tai standardoituja menettelytapoja. Toisaalta tehokas toimitusketju vaatii myös informaation nopean virtauksen läpi koko toimitusketjun. (Stevenson 2014, pp.678-679.) Esimerkiksi muutokset projektitasolla on kyettävä viestittämään sekä kohdeyrityksen että toimitusketjun sisällä riittävän nopeasti, ettei projektien toteutus kärsi.

### 3.3 Ennustaminen alkuhetkellä

Projektien suunnittelusta syntyy jokaiselle projektille ainutlaatuinen tuoterakenne. Tämä niin kutsuttu osaluettelo sisältää projektiin suunniteltuja varastonimikkeitä ja komponentteja. Projektien osaluettelot sisältävät kuitenkin muutamia perustavanlaatuisia ongelmia. Ensinnäkin osaluetteloon tehdyt merkinnät projekteissa tarvittavista nimikkeistä eivät vastaa kovinkaan tarkasti todellista nimikkeiden tarvetta. Osaluettelon mukaiset varaukset ovat keskimäärin huomattavasti pienempiä kuin todelliset kulutukset projektien osalta. Osaluetteloa ei ole täten pystytty kunnolla hyödyntämään nimikkeiden kysynnän ennakoimisessakaan.

Osaluetteloiden toinen merkittävä ongelma liittyy ajoitukseen. Osaluettelossa nimikkeiden varaukset on suunniteltu tietyissä projektien vaiheissa käytettäväksi. Suunnittelusta johtuen osaluetteloiden suunnitellut jaksotukset eivät kuitenkaan pidä paikkansa. Suunnittelussa on yleistä merkitä tietyn alueen kaikki varaukset ensimmäiseen mahdolliseen vaiheeseen. Tämä ei kerro todellista tarveajankohtaa nimikkeille, ja se hankaloittaa nimikkeiden hankintaa. Toisaalta varastonimikkeitä voidaan myös kuluttaa ilman osaluettelomerkintöjä, mikä hankaloittaa kysyntään varautumista.

Eräs ongelma syntyy myös osaluetteloiden päivittämisestä ja nimikkeiden lisäämisen ajankohdasta. Suunnittelijoilla on tapana päivittää osaluetteloa ja sen mukaisia nimikkeiden varauksia projektin kuluessa. Tämä hankaloittaa osaluetteloon pohjautuvaa ennustamista ja kysyntään varautumista. Suunnittelijoilla on myös tapana lisätä uusia osaluettelovarauksia projektin kuluessa. Usein uudet varaukset saattavat tapahtua ajallisesti lähellä nimikkeiden tarvepäivämäärää. Jos tällaisella nimikkeellä on pidempi toimitusaika kuin varauksen lisäyksen ja tarvepäivämäärän välinen aika, ei osaluetteloon pohjautuvalla ennustamisella ole mahdollista kysyntään varautua.

Varastonimikkeiden kulutuksen ennakoiminen hoidetaan tällä hetkellä melkein puhtaasti asiantuntija-arvioiden avulla. Tilastollista ennustamista ei hyödynnetä kohdeyrityksen osalta juurikaan. Nimikkeiden kulutusta arvioidaan aiempien projektien kokonaiskulutuksen perusteella sekä projektien osaluettelovarausten avulla. Kohdeyrityksellä ei ole ennustamiseen suunniteltua järjestelmää tai ennustamisen prosessia käytössään, vaan eri materiaalinimikkeiden tulevan kysynnän ennakoimiseen on erilaisia käytäntöjä. Osa nimikkeistä hallitaan hälytysrajoilla ja varmuusvarastoilla, kun taas suureen osaan nimikkeistä käytetään asiantuntijoiden arvioita. Nimikkeiden mahdollista kysyntää ennakoidaan vanhojen projektien avulla ja toisaalta tarkastelemalla sen hetkisiä osaluettelovaroja.

Paikan päällä toimivat jälleenmyyjät hoitavat suurimman osan nimikkeistä ja niiden ennustamisesta. Kohdeyritys osallistuu kuitenkin yhteistyössä kysynnän ennakoimiseen ja toimittaa dataa toimittajille auttamaan ennustamista. Data sisältää tuoterakenteen mukaiset materiaalinimikkeiden varaukset projekteille sekä yhteenvedon muutaman aieman projektin tarvitsemista materiaalinimiketarpeista. Näiden avulla toimittajat pystyvät arvioimaan mahdollisen kulutuksen parhaillaan käynnissä olevan projektin osalta. Paikan päällä toimivat toimittajat käyttävät apunaan joitain ennustamisen menetelmiä, mutta pääsääntöisesti heidänkin ennustamisensa perustuu asiantuntija-arvioihin.

### 3.4 Ennustamisen tarve

Kohdeyrityksellä on erilaisia varastonimikkeitä tarkasteluhetkellä 12 717, joista noin 5 000:ta käytetään yksittäisessä projektissa. Näille kaikille nimikkeille halutaan kysynnän ennusteet, joiden avulla toimitusketjua pystytään paremmin hallitsemaan. Osa nimikkeistä ovat projektikohtaisia, mikä tarkoittaa, että niitä käytetään vain tiettyyn projektiin tai tietyn tilaajan projekteihin. Suurin osa aktiivisista nimikkeistä on kuitenkin useammassa projektissa hyödynnettäviä. Lähtökohtaisesti tämän tutkimuksen piiriin kuuluvat kaikki varastonimikkeet.

Ennusteiden aikajaksojen pituuksien valinta riippuu nimikkeiden toimitusajoista. Nimikkeillä on useita erilaisia toimitusaikoja riippuen tuotteen ominaisuuksista ja teknisestä monimutkaisuudesta sekä toimittajien valmiuksista toimittaa tilatut tuotteet. Nimikkeiden toimitusajat vaihtelevat yhden päivän ja puolen vuoden välillä. Ennustettavat aikavälit alkutilanneanalyysin perusteella ovat lyhyen aikavälin ennuste (n. 1 vko tai 1 kk) sekä pidemmän aikavälin ennuste (n. 1 vuosi). Nimikkeiden ominaisuuksien takia lyhyemmän aikavälin ennustejaksolla ei ole merkittävää hyötyä varastohallinnan kannalta. Myöskään pidempi ennuste ei paranna tässä tapauksessa varastohallintaa. Toisaalta, kuten luvussa 2 mainittiin, ennusteen tarkkuus huononee ennusteen aikajakson kasvaessa.

Varastonimikkeitä tarvitaan projekteissa tietty määrä. Alihankkijat ja kohdeyrityksen tuotanto voivat kuitenkin tilata tästä poikkeavan määrän nimikkeitä. Yleistä on, että tilataan suurempi määrä kuin tarvitaan, jotta nimikkeet varmasti riittävät. Osa nimikkeistä palautetaan takaisin kohdeyritykselle, mikä luo oman haasteensa varaston hallinnalle. Tässä tutkimuksessa keskitytään tutkimaan varastonimikkeiden kysyntää eikä niiden todellista kulutusta. Kulutuksen ennustaminen ei poista sitä ongelmaa, että asiakkaat tilaavat nimikkeitä enemmän kuin tarvitsevat. Jos ennustettaisiin vain kulutuksen mukaan, ei pystyttäisi täyttämään asiakkaiden tilauksia. Kuten luvussa 2 huomautetaan, on ennustaminen vain objektiivinen näkemys tulevaisuuden tilasta. Ennustamisen avulla voidaan suunnitella ja tehdä päätöksiä varaston hallinnan parantamiseksi.

## 4. DATAN ANALYSOINTI JA TULOKSET

Tässä luvussa tutkitaan kohdeyrityksen varastonimikkeiden ominaisuuksia sekä ennustettavuutta ja testataan erilaisia malleja kysynnän ennustamiseen. Luvun tarkoituksena on selvittää ovatko kohdeyrityksen varastonimikkeet ennustettavissa ja luoda viitekehys niiden kysynnän ennustamiseen. Luvussa testaan aiemmin esiteltyt teoriat hyödyntäen kohdeyrityksestä kerättävää empiiristä aineistoa. Tämän lisäksi pohditaan aiempien tutkimusten esittämien teorioiden soveltuvuutta kohdeyrityksen tilanteeseen. Tulososiossa suoritetaan tilastollinen tutkimus, jossa ennustettavuus selvitetään ja luodaan pohja käytännön ennustamiselle.

Luvun rakenne muistuttaa ennustusprosessin rakennetta, joka on esitelty kuvassa 1. Ennustusprosessi lähtee liikkeelle ennustettavan ilmiön määrittelystä ja päätöksestä ennusteen kohteesta. Tätä ennustusprosessin vaihetta vastaa alkutilanneanalyysi, jonka perusteella tehdään päätös, missä mittakaavassa lähdetään ennustamaan ja mitä nimikkeitä. Ennustusprosessin mukaisesti varastonimikkeiden kysyntädata kerätään ja puhdistetaan, jotta ennustettavuus ja ennustustarkkuus saadaan realistisesti esille. Kysyntädata analysoidaan aiempien lukujen teorioiden avulla ja samalla pohditaan teorioiden pätevyyttä kohdeyrityksen tilanteeseen nähden. Datan analysoinnissa huomioidaan niin tilastolliset menetelmät kuin myös harkintaan perustuvat johtopäätökset esimerkiksi datan luotettavuudesta, käytettävyydestä ennustamiseen ja saatavuudesta.

Luvussa suoritetaan kattava ennustusmallien testaus, jossa mallien ominaisuuksia ja sopeutuvuutta testataan määritetyn tarkasteluajanjakson avulla. Luvun tarkoituksena on selvittää, mitkä tekijät vaikuttavat ja parantavat ennustustarkkuuksia. Ennustusmallien testauksella pyritään myös asettamaan ennustusprosessille ja ennustusjärjestelmälle tarpeita ja tavoitteita sekä ottamaan kantaa vaadituille ominaisuuksille. Tämä osio vastaa ennustusprosessin vaihetta ennustemallin valinnasta. Ennustusmallien testauksella otetaan kantaa myös ennusteiden virheiden mittaamiseen ja tämän toiminnan vaatimuksiin osana kohdeyrityksen ennustusprosessia.

Luvussa pohditaan myös ennusteen luomista, joka vastaa ennustusprosessin viidettä vaihetta. Ennusteen luomisessa otetaan huomioon muun muassa sen käyttötarkoitus, käytettävyys, tarkkuus, käyttäjät ja datan kerääminen sekä analysointi. Ennusteen luomisessa otetaan huomioon myös ennustamisen jatkuvuus ja prosessimaisuus osana va-

rastionhallintaa. Tarkoituksena on pystyä ennustamaan varastonimikkeiden tulevaa kysyntää toistuvasti ja osittain automatisoidusti, mikä vähentää tarvittavia henkilöstöresursseja.

Empiirisen tutkimukseen valitaan tarkasteluajanjakso, joka sisältää neljä edellistä projektia sekä kaksi tarkasteluajanhetkellä käynnissä olevaa projektia. Ajallisesti tarkasteluajanjakso on noin 4 vuotta ja 9 kuukautta. Tämän avulla suoritetaan niin datan analysointi, ennustusmallien testaus kuin myös ennustusmallien virheiden vertailu. Ajanjakso jaotellaan vielä erikseen sovitus- ja ennustussegmenttiin. Sovitussegmentillä optimoidaan ennustusmallit ja testataan ne aikasarjaan, kun taas ennustussegmentillä simuloidaan mallien toimivuutta uudelle aikasarjalle ja vertaillaan mallien tarkkuutta. Ennuste-segmentin avulla tehdään varsinainen mallien vertailu ja ennustevirheiden tarkastelu, kun taas sovitussegmenttiä hyödynnetään mallien optimoimiseen esimerkiksi muuttuvien painokertoimien osalta.

## 4.1 Datan kerääminen

Data kerätään kohdeyrityksen materiaalinhallintajärjestelmästä, johon raportoidaan kaikki varastomateriaalien tilaukset. Data pystytään järjestämään useisiin eri muotoihin, mutta tässä tutkimuksessa se kerätään siten, että tilaukseen on liitetty tuotteen tarvepäivämäärä, kohdeprojekti ja tilattu määrä tietyssä yksikössä nimikkeen ominaisuuksien mukaan. Nimikkeiden yksiköitä ovat metri, kappalemäärä, neliömetri, litra, erä tai kilogramma. Data saadaan tuotua ulos kohdeyrityksen järjestelmästä Microsoft Exceliin, jossa suoritetaan tämän luvun empiirinen tutkimus.

Datan keräämiseen liittyy muutamia perustavanlaatuisia päätöksiä, jotka pitää ottaa huomioon. Eräs liittyy datan päivämäärän valintaan, koska data voidaan kerätä joko siten, että tarkastellaan ajankohtaa, jolloin tilaus on tehty tai ajankohtaa jolloin tilaus lähetetään asiakkaalle. Samoin pitää päättää käytetäänkö asiakkaan tilaamaa määrää vai toteutunutta lähetettyä määrää. Toisaalta datan keräämisessä pitää päättää miten palautukset huomioidaan. Tässä tutkimuksessa käytetään päivämääränä asiakkaan haluamaa toimituspäivää, joka on määritelty tilauksissa. Määränä käytetään asiakkaan tilaamaa määrää, koska lähetetystä määrästä voi puuttua nimikkeitä toimitusvaikeuksien takia. Lähetetty määrä voi myös muuttua, jos esimerkiksi nimikkeiden pakkauskoot eivät sovi tilaukseen kanssa yhteen. Palautuksia ei huomioida datassa, koska halutaan ennustaa nimikkeiden kysyntää eikä lopullista kulutusta.

## 4.2 Datan puhdistus

Data vaatii paljon puhdistusta tutkimuksen suorittamiseksi. Datan puhdistuksen voidaan nähdä olevan jopa tärkein vaihe ennustusprosessissa. Datan puhdistamisessa pitää ottaa huomioon muun muassa puuttuvat arvot, mahdolliset poikkeavuudet ja epätavalliset arvot. Datan puhdistaminen ja näiden epätavallisten arvojen tunnistaminen pystytään usein automatisoimaan järjestelmien avulla, joka tunnistaa poikkeavat arvot ja korjaa aikasarjan vastaamaan paremmin toteutunutta kysyntää.

Kohdeyrityksen data vaatii puhdistamista nimikkeistön osalta. Nimikkeistössä on useita nimikkeitä, jotka ovat poistumassa käytöstä tai niitä ei enää käytetä projekteissa. Kaikkiaan 12 717:sta nimikkeestä 4314 ei ole ollut kysyntää tarkasteluajanjaksolla. Kysyntättömiä nimikkeitä ei voida kuitenkaan poistaa kokonaan käytöstä tai jättää niitä pois ennustamisen laajuudesta, koska niitä voidaan yhä tarvita tulevissa projekteissa. Tässä tutkimuksessa keskitytään kuitenkin pääsääntöisesti jo käytettyjen nimikkeiden ennustamiseen. Tämän lisäksi fokus on sellaisissa nimikkeissä, joita ei ole aiemmin käytetty, mutta joita tiedetään käytettävän tulevaisuudessa.

Jokainen nimikkeen tilaus on kohdistettu tietylle projektille. Projektien osalta nimikkeet kuluvat samankaltaisesti tuoteryhmien sisällä. Projekteja voidaan täten vertailla keskenään nimikkeiden kulutuksen osalta ja kohdeyrityksen alkutilanteessa ennustaminen ja harkinnalliset päätökset perustuvatkin pääsääntöisesti aiempien projektien tarkasteluun. Projektit eivät kuitenkaan ole keskenään samanlaisia. Projektien koko vaihtelee huomattavasti, mikä vaikuttaa myös oleellisesti nimikkeiden kulutukseen. Jokainen projekti on myös ainutlaatuinen, jolloin siinä käytettävät nimikkeet voivat vaihdella. Toisaalta projektit ovat käynnissä samanaikaisesti, mikä lisää riskiä virheellisille tilauksien kohdistuksille. Dataa puhdistetaan korjaamalla tilauksille määriteltäviä projektikohdistuksia. Osa kohdistuksista on tehty sellaisille projekteille, jotka on saatu jo valmiiksi. Nämä tilaukset kohdistetaan oikeille projekteille, jotta ennustamisen tarkkuus paranee.

Kohdeyrityksen varastonimikkeillä ei ole juurikaan poikkeavia tapahtumia, jotka vaikuttaisivat kysyntään merkittävästi. Koska varastonimikkeitä ei myydä kohdeyrityksen ja projektien ulkopuolelle, ei niihin kohdistu esimerkiksi mainoskampanjoita. Varastonimikkeitä tilataan projektin tarpeiden mukaisesti ja niille löytyy tarkka kohde projektissa. Jonkin verran on kuitenkin havaittavissa varastonimikkeiden tankkausta. Tätä esiintyy varsinkin ennen kesälomia, kun varastonimikkeitä tilataan enemmän kuin tarvitaan, jotta ne varmasti riittävät kesälomien yli. Tällainen kulutuskäyttäytyminen näkyy vähäisinä kysyntäpiikkeinä, jotka on hyvä ottaa huomioon.



### 4.3 Datan analysointi

Luvun 2 ohessa tehdyn kirjallisuuskatsauksen ja aiempien tutkimuksien tarkastelun perusteella huomataan suoraan, että varastonimikkeiden kysynnän ennustamista ei ole juurikaan tutkittu projektiliiketoiminnassa. Aiemmat tutkimukset liittyvät pääsääntöisesti jatkuvan liiketoiminnan tapauksiin, joissa ei ole selviä suuria projektinomaisia kokonaisuuksia. Tämä luo haasteen yleisten teorioiden hyödyntämiselle sekä niiden pätevyydelle kohdeyrityksen tapauksessa. Tutkimuksen validiteetti on mahdollista kyseenalaistaa, koska käytettävät teoriat pohjautuvat pääsääntöisesti jatkuvan liiketoiminnan tapauksiin.

Tätä ongelmaa voidaan lieventää joko kehittämällä jo esiteltyjä teorioita kohdeyrityksen tilanteeseen sopivammiksi tai manipuloidamalla dataa niin, että se soveltuu teorioihin paremmin. Myöhemmin tässä luvussa tullaan huomaamaan, että pääsääntöisesti ongelma pyritään ratkomaan datan manipuloinnilla, mutta myös teorioita kehitetään ja testataan parempien tuloksien saavuttamiseksi.

Kysynnän ennustamiseen tarvittavaa dataa arvioidaan sen ominaisuuksien avulla. Kohdeyrityksen tilanteessa kerätyn datan voidaan sanoa olevan laadukasta. Data on hyvin raportoitu materiaalinhallintajärjestelmään, josta se saadaan kerättyä halutussa muodossa analysointia varten. Varastonimikkeiden kaikki tilaukset raportoidaan järjestelmää mahdollisimman tarkasti ja korjataan muutosten ilmaantuessa. Datan tarkkuus voidaan olettaa hyvin suureksi, vaikka joitain inhimillisiä virheitä se saattaa sisältää. Dataa pystytään keräämään jatkuvana prosessina, jolloin sen ajantasaisuus pystytään myös varmistamaan.

Kerätty data myös edustaa hyvin varastonimikkeiden kysyntää ja asiakkaiden todellisia tarpeita. Tämä on otettu huomioon keräysvaiheessa tehdyissä päätöksissä. Kerätyn datan johdonmukaisuus riippuu kohdeyrityksen tapauksessa pitkälti päätöksistä muuttaa prosessia tai ennustamisen tarkoitusta. Data saadaan johdonmukaiseksi, kun se kerätään johdonmukaisesti tietyin väliajoin ja ehdoin. Datassa voi olla hieman virheitä liittyen kysynnän kohdistamiseen tai tarveajankohtaan, mutta yleisesti sen voidaan todeta olevan laadukasta.

#### 4.3.1 Nimikkeistön ennustettavuus

Nimikkeiden kysyntää raportoidaan kohdeyrityksen järjestelmään tilauksien saapuessa, mikä tarkoittaa, että kyseessä on jatkuva aikasarja. Ennustamisen mielekkyyden kan-

nalta aikasarjat muutetaan diskreeteiksi summaamalla tilaukset samanpituisille aikajaksoille. Projektien keskimääräisten kestojen ja varastonimikkeiden keskimääräisten toimitusaikojen perusteella diskreeteiksi aikasarjojen aikaväleiksi valitaan viikko ja kuukausi, joille tilaukset summataan.

Nimikkeistö voidaan luokitella variaatiokertoimen avulla. Variaatiokerroin, joka on esitelty kaavassa (45), kuvaa kysynnän hajontaa suhteessa kysynnän keskiarvoon. Variaatiokerroin on yksinkertainen tapa luokitella eri aikasarjojen ennustettavuutta ja se kuvastaa hyvin ennusteen laatua ja toisaalta kysynnän luonnetta. Sandersin (2015) mukaan variaatiokertoimen mukaan aikasarjat voidaan luokitella kolmeen kategoriaan: vakaat (< 20 %), epävakaat (< 50 %) ja ennustamattomat (> 100 %). Taulukossa 3 on esitetty kohdeyrityksen varastonimikkeiden jaottelua näiden luokkien mukaan aikaväliltään sekä viikon että kuukauden mittaisissa diskreeteissä aikasarjoissa.

**Taulukko 3.** Varastonimikkeiden luokittelu variaatiokertoimen CV avulla.

CV	Kaikki		Kysynnälliset	
	1 vko	1 kk	1 vko	1 kk
Alle 20%	0%	0%	2%	2%
20-49%	0%	0%	15%	17%
50-99%	0%	5%	43%	46%
100-199%	5%	15%	41%	34%
200-299%	10%	17%	0%	0%
300-399%	11%	17%	0%	0%
400-499%	9%	13%	0%	0%
500-599%	9%	12%	0%	0%
600-699%	7%	3%	0%	0%
700%-	48%	19%	0%	0%
<b>Summa</b>	100%	100%	100%	100%

Taulukossa 3 on esitettyinä kaikkien aktiivisten 12 717 nimikkeen variaatiokertoimen luokittelu. 8329 nimikkeelle pystyttiin laskemaan variaatiokerroin, lopuilla ei ollut kysyntää tarkastellulla ajanjaksolla, jolloin variaatiokerrointa ei laskettu. Taulukossa on laskettu variaatiokerroin sekä kaikille havainnoille tarkastellulla ajanjaksolla että ainoastaan sellaisille aikaväleille, joilla kysyntää esiintyy. **Kaikki**-sarake antaa kuvan koko aikasarjan ennustettavuudesta, kun taas **Kysynnälliset**-sarake kuvastaa kysynnän ennustettavuutta, ainoastaan silloin kun kysyntää esiintyy. Tässä sarakkeessa pitää huomioida

myös kysynnän esiintymisen ennustettavuus, jota tutkitaan lisää myöhemmin tässä luvussa. Taulukosta huomataan, että kysynnän esiintyessä se on huomattavasti paremmin ennustettavissa.


Taulukosta 3 huomataan, että kohdeyrityksellä ei ole ollenkaan vakaita nimikkeitä, kun huomioidaan kaikki aikajaksojen arvot. Epävakaita on ainoastaan kuukauden mittaisten aikasarjojen osalta 5 % ja loput nimikkeet ovat ennustamattomia. Jos huomioidaan ainoastaan aikavälit, joissa esiintyy kysyntää, on nimikkeiden ennustettavuus huomattavasti parempi. Viikon ja kuukauden mittaisten aikavälien välillä ei ole merkittävää eroa, kun tarkastellaan vain kysynnällisiä aikajaksoja. Taulukosta huomataan, että kysynnän suuruus on pääsääntöisesti epävakaata ja noin 34 – 41 % nimikkeistä ovat ennustamattomia. Kysynnän suuruuden lisäksi on kuitenkin pystyttävä ennustamaan myös kysynnän ajoittuminen. Taulukossa 3 on hyvä huomioida, että mukana on myös sellaiset nimikkeet, joilla on ollut vain yksi kysyntä tarkastelulla ajanjaksolla ja joiden CV arvo on 0. Tällaisten nimikkeiden CV on muutettu 100 %:ksi, koska tämä kuvastaa paremmin nimikkeen ennustettavuutta.

Variaatiokertoimen avulla tehdyn tarkastelun perusteella voidaan valita ennustamisen aikasarjojen aikaväliksi kuukausi, joka tarkastelun perusteella antaisi paremman ennustettavuuden nimikkeille. Tätä tukee myös alkutilanneanalyysissä kartoitettu ennustamisen tarve sekä toimittajilta että kohdeyrityksen varastohallinnasta vastaavilta asiantuntijoilta.

### 4.3.2 Nimikkeistön kategorisointi


Taulukon 3 mukaan voidaan päätellä, että suurin osa nimikkeistä on hitaasti kuluvia. Tällaisille nimikkeille on taulukon 1 mukaan ominaista, että kysynnän esiintyminen on epäsäännöllistä, mutta kysynnän määrän vaihtelu on tasaisempaa. Tämän lisäksi kohdeyrityksellä on jonkin verran satunnaisia ja paakkuisesti kuluvia nimikkeitä.

Nimikkeistö voidaan kategorisoida variaatiokertoimen neliön ja kahden kysynnän keskimääräisen aikavälin avulla, kuten kuvassa 3 esitetään. Kategorisoimiseksi tarvittavat sopivat katkaisuarvot ovat  $CV^2 = 0,49$  ja  $p = 1,32$  aiempien tutkimuksien perusteella (Böylan et al. 2008). Kuvassa 5 on esitettyä nimikkeistön variaatiokertoimien neliöiden ja kysyntäväliden riippuvuus.



**Kuva 5.** Nimikkeistön kategorisointi variaatiokertoimen neliön ja kysyntävälin avulla.

Kuva 5 on skaalattu esittämään katkaisuarvojen läheisyys. Katkaisuarvot on esitetty punaisina viivoina. Todellisuudessa kysyntäväli vaihtelee 1 ja 57 välillä. Mitä pienempi kysyntäväli  $p$  on, sitä useammin nimikettä on kulunut. Vastaavasti keskimääräisen kysyntävälin ollessa 57 on nimikettä kulunut vain yhden kuukauden aikana tarkasteluajanjaksoilla. Variaatiokertoimen neliön arvot vaihtelevat 0 ja 23,35 välillä. Kuvassa 6 on esitettyä nimikkeistön kategorisointi variaatiokertoimien neliöiden ja kysyntävälien avulla, kun katkaisuarvot ovat edellä mainitut.



**Kuva 6.** Nimikkeistön kategorisointi variaatiokertoimen neliön ja kysyntävälän avulla.

Kuvassa 6 nimikkeistön kategorisointi osoittaa, että tasaisen kysynnän nimikkeitä on 3 %, epävakaita 4 %, ajoittaisia 38 % ja paakkuisia 37 %. Kategorisoimisessa on huomioitu ainoastaan nimikkeet, joilla on ollut tarkasteluajanjaksolla vähintään 2 kysynnällistä aikaväliä. Näin saadaan realistinen kuva variaatiokertoimen neliöstä, joka yhden kysynnän tapauksessa on 0. Tällaisia yhden kysynnän nimikkeitä on 1 553 eli 18 % tarkasteltavista nimikkeistä. Tarkastelussa ei huomioitu nimikkeitä, joilla ei ole ollut tarkastelujaksolla kysyntää ollenkaan.

Kuvasta 5 huomataan, että suurin osa nimikkeistä on kysyntävälän perusteella epätasaisesti kuluvia. Kysynnän tasaisuuden puolesta nimikkeistö jakaantuu suunnilleen puoliksi, kun variaatiokertoimen katkaisuarvo on 0,49. Keskimääräisen kysyntävälän mukaan nimikkeistä vain 7 prosenttia on tasaisesti kuluvia. Variaatiokertoimen ja kysyntävälän avulla tehty nimikkeistön kategorisointi viittaa epäsäännöllisten ennustemallien olevan kohdeyrityksen tilanteessa tarkimmin toimivia.

Nimikkeistö voidaan kategorisoida myös puhtaasti sen mukaan, minkälainen nimike on kyseessä. Kuten alkutilanneanalyysissä selvitettiin, osa nimikkeistä on projekteihin meneviä nimikkeitä, kun taas osaa nimikkeistä käytetään tuotannon tukitoimintoihin ja yrityksen sisäisesti. Tällaiset nimikkeet eivät riipu projektin vaiheesta samalla tavalla kuin projekteihin suoraan käytettävät nimikkeet. Näiden nimikkeiden osuus on kuitenkin datan analysoinnin perusteella erittäin pieni, minkä takia tämän tyyppinen jaottelu ei ole järkevää.

Nimikkeiden jaottelussa voidaan hyödyntää myös kohdeyrityksen käyttämiä materiaali-ryhmiä. Varastonimikkeet on jaoteltu ryhmiin siten, että yhdessä ryhmässä on saman tyyppisiä nimikkeitä. Materiaaliryhmiä on tarkasteluajanhetkellä 531, ja tarkasteluajanjaksossa käytettyjä ryhmiä 195. Materiaaliryhmän sisällä olevat nimikkeet kuuluvat samaan tuoteryhmään ja niillä on samankaltaisia ominaisuuksia. Yhden ryhmän sisäiset nimikkeet käyttäytyvät jossain määrin samalla tavalla. Myös nimikkeiden kulutuskäyttämiset muistuttavat ryhmän sisällä toisiaan. Kun tarkastellaan nimikkeiden kulutusta projektin aikana, kuluvat saman materiaaliryhmän nimikkeet suunnilleen samoissa projektien vaiheissa materiaaliryhmästä riippuen.

Kohdeyrityksen varastomateriaalit voidaan luokitella myös niiden uutuuden perusteella. Kuten alkutilanneanalyysissä todettiin, on harmonisoinnin seurauksena nimikkeiden lukumäärä kasvanut merkittävästi. Uusilla nimikkeillä ei ole alkutilanteessa kysyntähistoriaa kovinkaan paljon, mikä vaikeuttaa ennustamista huomattavasti. Tästä syystä nimikkeistö saattaa olla järkevä kategorisoida harmonisoinnin perusteella. Nimikkeitä luodaan myös uusien tarpeiden mukaan, eikä näilläkään ole aiempaa kysyntähistoriaa, jonka avulla pystyttäisiin ennustamaan. Nimikkeiden, joilla ei ole kovinkaan paljoa kysyntähistoriaa, ennustaminen on syytä tehdä erillisenä prosessina verrattuna sellaisiin, joita on käytetty jo useammassa projektissa. Luvussa 2 esitellyt ennustamisen teoriat ja mallit perustuvat historiadatan hyödyntämiseen, mikä ei uusien nimikkeiden kohdalla ole mahdollista.

Nimikkeistö voidaan kategorisoida myös vasta ennustusmallin valinnan jälkeen, kuten aiemmissa tutkimuksissa on yleisesti tehty. Tässä tapauksessa ennustusmallit testataan kaikille nimikkeille samoilla olettamuksilla, ja nimikkeistö kategorisoidaan toteutuneiden virheiden avulla. Kuten taulukosta 2 huomataan, on ennustusmalleilla tietyntyyppisiä ominaisuuksia, jotka soveltuvat erilaisten aikasarjojen ennustamiseen. Tämän tyyppinen kategorisoiminen auttaa tilanteissa, joissa nimikkeitä ei pystytä pelkkien historiallisten aikasarjojen avulla kategorisoimaan. Toisaalta, kun ennustusmallit testataan kaikille nimikkeille samoilla olettamuksilla ennen kategorisoimista, kaikki ennustusmallit tulee testattua nimikkeille eikä malleja jää testaamatta kategorisoimisen takia.

#### **4.4 Ennustemallien vertailu**

Taulukossa 2 esitellyjä ennustemalleja lähdetään vertailemaan luvussa 2 esitellyjen virhemallien avulla. Ennustukseen käytetään neljää viimeisintä projektia sekä kahta käynnissä olevaa projektia. Tästä muodostettu kuukausittainen diskreetti aikasarja jaotellaan sovitus- ja ennustussegmenttiin, joista sovitussegmentti käsittää kuukausikohtaiset kysynät vuoden 2018 toukokuuhun asti. Viimeinen vuosi toukokuusta 2018 vuoden 2019

toukokuuhun toimii ennustussegmenttinä. Toisin sanoen ennustusmalleja testataan viimeisen vuoden mittaiselle ajanjaksolle.

Vertailtavina ennustemalleina hyödynnetään luvussa 2 esiteltyjä tilastollisia malleja. Monimuuttajaennustaminen jätetään testauksesta pois, koska kohdeyrityksen nimikkeistölle ja nimikkeiden kysynnän luonteen kannalta tämän kaltainen ennustaminen ei ole mielekäästä. Nimikkeiden kysyntään ei esimerkiksi vaikuta suoranaisesti hinta tai markkinoinnin määrä, vaan nimikkeitä kulutetaan projekteissa tarpeen mukaan.

Ennustamisessa mallinnetaan kuukausittain tapahtuvaa ennustamista siten, että ennustussegmentissä ennusteissa voidaan käyttää aina edelliseen kuukauteen asti ulottuvaa historiadataa, mutta ennustemallien luomisessa ja optimoimisessa käytetään vain sovitusssegmenttiä. Näin päästään todellisuutta vastaavaan tilanteeseen, jossa ennustaminen tapahtuisi kuukauden väliajoin. Viimeisen vuoden ajalta syntyneitä ennusteita verrataan vastaaviin todellisiin kysynnän arvoihin, ja tämän pohjalta lasketaan eri mallien ennustevirheet. Ennustevirheiden analysoinnissa hyödynnetään useita erilaisia virhemalleja, jotta saadaan monipuolinen kuva ennustustarkkuudesta.

Aluksi testataan taulukon 2 ennustusmalleista sellaiset mallit, jotka eivät sisällä kausikomponenttia. Ennustuksen kohteena ovat kaikki varastonimikkeet, joilla on ollut kysyntää tarkasteluajanjaksolla. Ennustusmalleja on 10 kappaletta ja virhemalleja 6 kappaletta. Nimikkeitä ei tässä tilanteessa vielä kategorisoida, vaan kaikki mallit testataan jokaiselle nimikkeelle. Tilastollisista malleista jätetään pois myös Lineaarisen trendin malli, koska nimikkeiden kysyntä ei sisällä vahvaa trendikomponenttia toiminnan luonteen takia.

Taulukossa 4 on esiteltynä ennustemallien vertailu siten, että kaikille nimikkeille on laskettu eri mallien virhearvot ja vertailun avulla selvitetty, mikä malli antaa pienimmän virheen nimikkeille. Taulukossa on summattu nimikkeiden määrä eri ennustusmalleille eri virhemallien avulla laskettuna. Tarkastelussa on hyvä huomioida, että jos useampi malli antaa saman virhearvon, eli toimii yhtä hyvin, malliksi valitaan aina yksinkertaisempi malli. Mallit on lueteltu taulukossa 4 siten, että yksinkertaisin malli on ylimpänä. Liukuvan keskiarvon mallissa ennusteet lasketaan 3 ja 5 aikaisemman aikavälin avulla ja painotetun liukuvan keskiarvon mallissa 4 aikaisemman arvon avulla.

**Taulukko 4.** Kuukausiennustemallien valinta eri virhemallien avulla.

Virhemalli Ennustusmalli	MAE	MSE	RMSE	MPE	MAPE	sMAPE
<b>Naiivi</b>	2458	1782	1782	0	34	1742
<b>Random walk</b>	164	205	205	269	4	0
<b>Keskiarvo</b>	1562	526	526	9	114	0
<b>Liukuva 3+5</b>	509	807	807	12	47	0
<b>P.liukuva</b>	78	73	73	0	10	0
<b>Eks.</b>	336	656	656	3	96	1101
<b>Holt</b>	1148	1051	1051	209	41	4864
<b>Croston</b>	1327	1905	1905	6	42	298
<b>SBA</b>	492	967	967	0	102	117
<b>TSB</b>	255	357	357	0	18	207
<b>Ei sovi</b>	-	-	-	7821	7821	-
<b>Yhteensä</b>	8329	8329	8329	8329	8329	8329

Taulukosta 4 huomataan, että yksittäinen ennustemalli ei nouse selvästi paremmaksi kuin muut mallit. Taulukossa on korostettuna kunkin virhemallin avulla mitattu tarkin ennustemalli. Tämän mukaan parhaiten toimivat Naiivi-, Random walk-, Keskiarvo-, Crostonin ja Holtin mallit riippuen, millä virhemallilla tarkkuutta mitataan. Naiivimalli nousee suureen osaan, koska se toimii usean nimikkeen kohdalla yhtä hyvin kuin muut mallit. Kysyntähistorian jaksottaisuuden ja epätasaisuuden takia suhteelliset virhemallit eivät toimi kovinkaan hyvin, koska näiden osalta suurimmalle osalle nimikkeistä ei voida laskea virhearvoa. Vain 6 % nimikkeistä on ollut jokaisena kuukautena kysyntää.

Taulukon mukaan Naiivimalli sekä Crostonin ja Holtin mallit toimivat järjestäen muita paremmin. Yksittäisen suurimman arvon antaa Holtin malli, kun tarkkuutta mitataan sMAPE virhemallilla. Tässä tapauksessa Holt valikoituu jopa 58 %:lle nimikkeistä. Tällä virhemallilla pystytään huomioimaan hyvin myös kysynnättömät aikavälit, joita historiadatassa on paljon. Tämän tyyppinen tarkastelu ei ota kantaa siihen, kuinka paljon parempi jokin ennustemalli on suhteessa muihin malleihin, vaan ainoastaan siihen kuinka monen nimikkeen osalta tietty malli on parempi kuin muut mallit.

Taulukon 4 lähempi tarkastelu herättää kysymyksen vertailun mahdollisesta vinoutuneisuudesta uusien ja hitaasti kuluvien nimikkeiden takia. Nimikkeet, joilla on paljon kysynnättömiä kuukausia heikentävät huomattavasti ennustustarkkuutta malleilla, jotka eivät



ole tarkoitettu sellaisiin tilanteisiin. Toisaalta esimerkiksi Naiivimalli toimii suhteellisen hyvin pitkien kysynnättömien jaksojen aikana.

Keskimäärin nimikkeillä on ollut kysynnättömiä kuukausia 41, kun tarkasteluajanjaksolla on kuukausia yhteensä 53. Nimikkeitä, joilla on ollut vähintään joka toisena kuukautena kysyntää, on yhteensä 1182, joka on vain noin 14 % tarkastelluista nimikkeistä ja vain noin 9 % kaikista kohdeyrityksen nimikkeistä. Tätä puoltaa myös datan analysoinnissa tehty tarkastelu keskimääräisistä katkaisuarvoista, jotka on esitelty kuvissa 4 ja 5. Uusien nimikkeiden suuren määrän takia kategorisoidaan nimikkeet ennen harmonisointia jo käytössä olleisiin sekä uusiin nimikkeisiin.

Taulukossa 5 on esiteltynä sellaisten nimikkeiden kysyntä, jotka ovat olleet käytössä jo ennen nimikkeiden harmonisointia. Tällaisia nimikkeitä on 4320 ja se poissulkee uudet nimikkeet, joilla ei ole aiemmilta projekteilta kysyntää. Tämän tyyppinen kategorisointi antaa luotettavamman kuvan ennustemallien valinnasta jo käytössä olleille nimikkeille.

**Taulukko 5.** Kuukausiennustemallien valinta eri virhemallien avulla jo aiemmin käytössä olleille nimikkeille.

<b>Virhemalli</b> <b>Ennustusmalli</b>	<b>MAE</b>	<b>MSE</b>	<b>RMSE</b>	<b>MPE</b>	<b>MAPE</b>	<b>sMAPE</b>
<b>Naiivi</b>	1736	1396	1396	0	148	1229
<b>RW</b>	35	31	31	125	5	0
<b>Keskiarvo</b>	371	438	438	9	80	0
<b>Liukuva3+5</b>	214	288	288	7	9	0
<b>P.liukuva</b>	37	32	32	0	2	0
<b>EKS</b>	117	177	177	3	29	229
<b>Holt</b>	814	509	509	110	15	2319
<b>Croston</b>	460	609	609	6	26	285
<b>SBA</b>	383	672	672	0	69	101
<b>TSB</b>	153	168	168	0	3	157
<b>Ei sovi</b>	-	-	-	4060	3934	-
<b>Yhteensä</b>	4320	4320	4320	4320	4320	4320

Taulukossa 5 on käytetty samoja kertoimia ja sovitusssegmenttiä kuin taulukossa 4, mutta tarkastelusta on jätetty pois sellaiset nimikkeet, joita ei ole käytetty ennen nimikkeiden harmonisointia. Taulukon 5 analysoinnin perusteella huomataan, ettei nimikkeille löydy yksiselitteisesti yhtä parasta ennustemallia vaan mallien tarkimmat arvot jakautuvat sen

mukaan, mitä virhemallia hyödynnetään. Taulukon mukaan erityisen hyvin näyttävät toimivan kuitenkin Holtin ja Naiivimalli. Naiivimallin suuri määrä nimikkeissä selittyy jälleen sillä, että se valitaan maliksi, vaikka jokin muu malli toimisi yhtä hyvin. Suurin yksittäinen ero mallien välillä on nähtävissä sMAPE virhemallia käytettäessä, kun Holt valikoituu parhaimmaksi jopa 54 %:lle nimikkeistä.

Taulukot 4 ja 5 eivät ota kantaa virheen suuruuksiin vaan ainoastaan siihen, mikä malli toimii määrällisesti parhaiten kunkin virhemallin mukaisesti. Taulukossa 6 on esitelty keskimääräiset virhearvot kullekin ennustemallille, jolloin saadaan selville, mikä ennustemalli on keskimäärin tarkin koko nimikkeistön osalta.

**Taulukko 6.** *Kuukausiennustemallien keskimääräiset virheet nimikkeistölle.*

<b>Virhemalli</b> <b>Ennustemalli</b>	<b>MAE</b>	<b>MSE</b>	<b>RMSE</b>	<b>MPE</b>	<b>MAPE</b>	<b>sMAPE</b>
<b>Naiivi</b>	160.89	7721512.62	253.51	-0.83	1.32	0.90
<b>RW</b>	164.33	8322191.63	259.64	-1.01	1.43	1.12
<b>Keskiarvo</b>	198.33	12782442.30	296.25	0.14	1.04	1.73
<b>Liukuva3+5</b>	159.20	7434535.35	243.32	-0.75	1.22	1.04
<b>P.liukuva</b>	156.48	6885757.13	238.36	-0.81	1.23	1.11
<b>Eks.</b>	158.56	7132463.78	238.91	-0.05	1.03	1.64
<b>Holt</b>	156.44	6860556.97	238.30	-0.84	1.30	0.92
<b>Croston</b>	189.74	10529990.06	279.66	-0.20	1.13	1.74
<b>SBA</b>	178.97	11048196.35	270.39	-0.11	0.92	1.74
<b>TSB</b>	158.90	7623699.40	244.15	-0.52	1.14	1.72

Taulukosta 6 huomataan, että Holtin malli näyttäisi toimivan muita malleja paremmin suurimmalle osalle eri virhemalleja. Ainoastaan MPE- ja MAPE-malleja käytettäessä mallin virheet eivät tuota kovinkaan tarkkoja ennusteita. Tässä pitää kuitenkin huomioida, että kuten taulukosta 4 huomataan, vain 6 %:lle nimikkeistä voidaan laskea MPE ja MAPE arvot.

Nimikkeistön kategorisoimisen perusteella parhaimmiksi malleiksi olisi aikaisempien tutkimusten mukaan pitänyt valikoitua epäsäännöllisen kysynnän malleja. Crostonin, SBA- ja TSB-mallit on kehitelty nimenomaan epäsäännöllisen kysynnän aikasarjojen ennustamiseen. Kuten taulukoista 4, 5 ja 6 huomataan, kohdeyrityksen tapauksessa nämä eivät

kuitenkaan tuota tarkempia ennusteita verrattuna muihin malleihin. Jos ennustusjärjestelmässä ei ole ominaisuutta automaattiseen mallin valintaan jokaisen nimikkeen kohdalla, viittaa tehty tarkastelu ja analysointi käyttämään Holtin, Crostonin tai Naiivimallia.

#### 4.4.1 Kausiluonteisuuden huomioiminen

Aiemmassa luvussa tarkastellut ennustemallit eivät huomioi aikasarjojen kausiluonteisuutta laisinkaan. Nimikkeiden kausiluonteisuudelle antaa viitteitä kohdeyrityksen toiminnan luonne. Tulevien projektien materiaalien kysyntää voidaan arvioida tarkastelemalla aiempia projekteja. Projektien samankaltaiset ominaisuudet niin ajallisesti kuin käytettävien materiaalien osalta mahdollistavat projektikohtaisten ennusteiden luomisen aiempien projektien avulla. Kohdeyrityksen tilanteessa projekteja on kuitenkin käynnissä useampi samanaikaisesti, mikä hankaloittaa ennusteen luomista.

Ennustaminen voitaisiin suorittaa suoraan historiadatalla tunnistamalla kausiluonteisuus, kun projektit ovat käynnissä samanaikaisesti. Toinen vaihtoehto on datan manipulointi. Tässä tapauksessa nimikkeiden kysyntä jaetaan jokaiselle projektille erikseen. Kohdeyrityksen jokainen tilaus on aina kohdistettu tietylle projektille, minkä perusteella jokaiselle projektille voidaan luoda oma kysyntähistoria. Eri projektien kysyntähistoriat voidaan asettaa perä jälkeen, jolloin mallinnetaan tilannetta, jossa projektit suoritettaisiin alusta loppuun yksittäin, ja uusi projekti aloitettaisiin vanhan valmistuttua. Näin ennustetaan yksittäinen projekti kerrallaan aiempien projektien avulla ja lopullinen ennuste pysyttään laskemaan summaamalla käynnissä olevien projektien ennusteet yhteen halutulle aikavälille. Tässä manipuloidussa tilanteessa projektit elävät omaa projektiaikatauluaan, ja lopullinen ennuste saadaan eri projektien summana.

Kausiluonteisten ennustemallien testaus toteutetaan vastaavasti kuten aiemmassa luvussa esiteltyt mallit. Sovitussegmenttiä hyödynnetään mallien optimoimiseen ja sopeutumiseen, ja vastaavasti ennustussegmenttiä ennustevirheen mittaamiseen ja analysointiin. Taulukossa 7 on esiteltynä kausiluonteisten ennustemallien keskimääräiset ennustustarkkuudet koko nimikkeistölle. Kausiluonteisia ennustemalleja ovat Wintersin malli, kausiluonteinen liukuvan keskiarvon malli ja kausiluonteinen painotetun liukuvan keskiarvon malli. Molemmissa liukuvissa keskiarvon malleissa käytetään 4:ää edellistä aikaisempien projektien vastaavaa vaihetta.

**Taulukko 7.** Kausiluonteisten kuukausiennustemallien vertailu kaikille nimikkeille.

<b>Virhemalli</b> <b>Ennustemalli</b>	<b>MAE</b>	<b>MSE</b>	<b>RMSE</b>	<b>MPE</b>	<b>MAPE</b>	<b>sMAPE</b>
<b>Winters</b>	126.48	4614689.98	213.99	-0.82	1.28	11.86
<b>Liukuva S</b>	171.61	11233880.41	283.18	0.56	1.10	7.33
<b>P.liukuva S</b>	170.93	10951063.00	281.83	0.57	1.09	7.82

Taulukosta 7 huomataan, että Wintersin malli toimii sekä taulukon 6 että taulukon 7 malleihin verrattuna erittäin hyvin. Wintersin malli antaa huomattavasti pienemmän keskimääräisen virheen arvon MAE. Myös MSE ja RMSE virhemallit antavat huomattavasti pienemmän virhearvon. Suhteellisten virhemallien osalta MPE- ja MAPE-mallit toimivat heikommin, mutta on hyvä muistaa, että vain murto-osalle nimikkeistä voidaan kyseiset virhearvot laskea. Korkea sMAPE virhearvo taas liittyy sen ominaisuuksiin. Jos kysyntä tai ennuste aikavälillä on 0, niin sMAPE on kyseiseltä aikaväliltä 2, vaikka ero olisikin todellisuudessa pieni. Kausiluonteisten mallien korkea sMAPE arvo viittaa tähän ilmiöön.

Taulukossa 8 on vielä yhdistetty kaikki tutkitut mallit ja eri virhemallien avulla valittu jokaiselle nimikkeelle paras mahdollinen ennustemalli.

**Taulukko 8.** Kuukausiennustemallien valinta eri virhemallien avulla.

Virhemalli Ennustusmalli	MAE	MSE	RMSE	MPE	MAPE	sMAPE
<b>Naiivi</b>	2067	1684	1684	0	300	1712
<b>Random walk</b>	142	180	180	227	10	0
<b>Keskiarvo</b>	48	135	135	7	89	0
<b>Liukuva 3+5</b>	331	646	646	10	40	0
<b>P.liukuva</b>	37	49	49	0	9	0
<b>Eks.</b>	219	413	413	3	84	1055
<b>Holt</b>	745	779	779	165	41	4562
<b>Croston</b>	127	1265	1265	5	41	301
<b>SBA</b>	142	509	509	0	90	119
<b>TSB</b>	126	193	193	0	20	206
<b>Winters</b>	983	1007	1007	87	17	1
<b>Liukuva S</b>	744	575	575	1	9	58
<b>P.liukuva S</b>	2618	894	894	3	9	315
<b>Ei sovi</b>	-	-	-	7821	7570	-
<b>Yhteensä</b>	8329	8329	8329	8329	8329	8329

Taulukosta 8 huomataan, että kausiluonteiset mallit toimivat kohdeyrityksen tilanteessa hyvin. Toisaalta myös Naiivimalli toimii suhteellisen hyvin, kun otetaan huomioon kaikki nimikkeet, koska se antaa usean nimikkeen kohdalla vähintään yhtä tarkan ennusteen muiden mallien kanssa. Mitattaessa sMAPE virhemallin mukaan valikoituu Holtin malli jopa 55 %:lle nimikkeistä. Taulukon 8 tuloksissa on hyvä huomioida, että mukana on paljon sellaisia nimikkeitä, jotka on otettu käyttöön harmonisoinnin seurauksena. Tällaisille nimikkeille eivät kausiluonteiset mallit toimi kovinkaan hyvin. Taulukossa 9 on huomioitu tämä ja laskettu mallien sopivuus vain ennen harmonisointia käytössä olleille nimikkeille.

**Taulukko 9.** Kuukausiennustemallien valinta eri virhemallien avulla jo aiemmin käytössä olleille nimikkeille.

Virhemalli Ennustusmalli	MAE	MSE	RMSE	MPE	MAPE	sMAPE
<b>Naivi</b>	1429	1304	1304	0	145	1224
<b>Random walk</b>	19	25	25	102	4	0
<b>Keskiarvo</b>	28	123	123	7	66	0
<b>Liukuva 3+5</b>	94	192	192	6	8	0
<b>P.liukuva</b>	12	21	21	0	2	0
<b>Eks.</b>	41	70	70	3	28	228
<b>Holt</b>	499	364	364	99	14	2206
<b>Croston</b>	72	241	241	5	26	283
<b>SBA</b>	102	280	280	0	63	101
<b>TSB</b>	44	48	48	0	3	156
<b>Winters</b>	805	768	768	34	11	1
<b>Liukuva S</b>	683	524	524	1	9	56
<b>P.liukuva S</b>	492	360	360	3	7	65
<b>Ei sovi</b>	-	-	-	4060	3934	-
<b>Yhteensä</b>	4320	4320	4320	4320	4320	4320

Taulukosta 9 nähdään, että myös usean sellaisen nimikkeen, joka on ollut käytössä jo ennen harmonisointia, tarkin ennuste saadaan yksinkertaisella Naiviimallilla. Toisaalta myös kausiluonteiset mallit antavat usealle nimikkeelle tarkimman ennusteen. Holtin malli antaa sMAPE virhemallilla mitattuna tarkimman tuloksen noin puolille nimikkeistä.

Kausiluonteisuuden huomioiminen osana ennustetta auttaa kategorisoinnissa havaittua ongelmaa siitä, ettei kysynnän ajankohtaa pystytä kunnolla ennustamaan. Kuten taulukosta 3 nähdään, on kysyntä ilmaantuessaan suhteellisen tasaista, mutta kysynnän esiintymisen ajankohdan ennustettavuus on huono. Kysynnän kohdistaminen eri projekteille ja jokaisen projektin ennustaminen erikseen parantaa kysynnän ajoittumisen ennustettavuutta.

Kaiken kaikkiaan kuukausikohtainen ennustaminen antaa suhteellisen tarkkoja ennusteita suurelle osalle nimikkeistä. Ongelmallisiksi muodostuvat nimikkeet, joilla ei ole riittävästi historiadataa tarkkojen ennusteiden luomiseen. Tällaiset nimikkeet ovat joko yksittäisiä uusia nimikkeitä, jotka ovat syntyneet tiettyyn tarpeeseen tai harmonisoinnin seurauksena käyttöön otettuja nimikkeitä. Ennustemallien vertailusta huomataan myös, että Naiivimalli toimii usean nimikkeen tapauksessa vähintään yhtä tarkasti kuin jokin muu malli.

#### **4.4.2 Kvartaali- ja vuosiennustaminen**

Kvartaaliennustamiseen mallit vertaillaan vastaavalla tavalla. Käytettävä tarkasteluajanjakso pysyy samana kuin kuukausiennustamisessa ja myös samoja ennustemalleja vertaillaan kuin kuukausikohtaisessa ennustamisessa. Ennustemallien optimoiminen suoritetaan samalla tavalla kuin kuukausikohtaisessa ennustamisessa. Ennusteita ja toteutuneita arvoja vertaillaan 6 kvartaalin ajalta, joka vastaa 18 kuukautta. Taulukossa 10 on esitetty ennustemallien vertailu ennustevirheiden avulla kvartaaliaikasarjoille. Kausiluonteisten mallien testauksessa on data jälleen manipuloitu, niin että kukin projekti ennustetaan erikseen ja lopullinen ennuste on saatu näiden yhdistelmänä.

**Taulukko 10.** Kvartaaliennustemallien vertailu virhearvojen avulla.

Virhemalli Ennustemalli	MAE	MSE	RMSE	MPE	MAPE	sMAPE
<b>Naiivi</b>	337.60	51847484.53	478.15	-1.36	1.87	3.47
<b>Random walk</b>	349.46	58226022.87	489.89	-1.62	2.06	4.19
<b>Keskiarvo</b>	523.99	184143008.71	681.88	-0.76	1.93	7.41
<b>Liukuva 3+5</b>	297.71	42162442.45	425.82	-1.78	2.20	4.04
<b>P.liukuva</b>	308.26	43976149.66	438.14	-1.78	2.20	4.29
<b>Eks.</b>	313.90	44463801.26	444.35	-1.88	2.31	1.12
<b>Holt</b>	370.03	62009577.44	499.54	-2.52	2.85	5.04
<b>Croston</b>	336.50	47661375.46	476.52	-1.76	2.29	8.27
<b>SBA</b>	339.63	54097134.16	485.01	-0.92	1.59	8.30
<b>TSB</b>	315.95	46439697.07	450.68	-1.68	2.13	8.30
<b>Liukuva S</b>	665.31	512932014.99	1120.62	-0.83	2.40	4.09
<b>Winters</b>	251.26	35411341.19	320.61	-1.36	1.96	4.71
<b>P.liukuva S</b>	311.25	53271271.67	521.59	0.53	1.17	4.08

Taulukosta 10 huomataan, että Wintersin ja Painotettu kausiluonteinen liukuva keskiarvomalli toimivat selvästi paremmin kuin muut mallit. Ainoastaan sMAPE virhemallin mukaan eksponentiaalinen tasoitus toimii huomattavasti paremmin kuin muut mallit. Taulukosta huomataan myös, että kuten luvussa 2 todetaan, ennustamisen tarkkuus pienenee ennustettavan aikavälin kasvaessa. Taulukkojen 6 ja 7 vastaavat arvot ovat huomattavasti pienempiä kuin taulukon 10. Ennustamisen epävarmuus ja kysyntään vaikuttavat lukuisat tekijät aiheuttavat muutoksia ja heilahduksia kysynnän määrään. Mitä pidempi ennustettava aikaväli on kyseessä, sitä suurempaa heilahtelu on.

Ennustemallien valintaa puhtaasti virhemallien avulla kvartaaliaikajaksoille on tutkittu taulukossa 11. Tarkasteluun on valittu ennustemallit ainoastaan jo ennen harmonisointia käytössä olleille nimikkeille.



**Taulukko 11.** Kvartaaliennustemallien valinta eri virhemallien avulla jo aiemmin käytössä olleille nimikkeille.

Virhemalli Ennustemalli	MAE	MSE	RMSE	MPE	MAPE	sMAPE
<b>Naiivi</b>	1103	979	979	0	56	978
<b>Random walk</b>	38	47	47	90	27	0
<b>Keskiarvo</b>	159	179	179	30	244	0
<b>Liukuva 3+5</b>	67	86	86	4	77	0
<b>P.liukuva</b>	12	16	16	0	18	0
<b>Eks.</b>	40	65	65	0	116	2713
<b>Holt</b>	22	41	41	629	26	0
<b>Croston</b>	18	80	80	0	58	0
<b>SBA</b>	71	201	201	0	104	0
<b>TSB</b>	7	25	25	0	30	0
<b>Liukuva S</b>	178	159	159	35	7	267
<b>Winters</b>	1647	1691	1691	678	695	331
<b>P.liukuva S</b>	957	752	752	0	8	31
<b>Ei sovi</b>	0	0	0	2854	2854	0
<b>Yhteensä</b>	4320	4320	4320	4320	4320	4320

Taulukon 11 mukaan parhaiten kvartaaliennustamiseen sopii kausiluonteiset mallit ja varsinkin Wintersin malli. Kuten taulukko 10 antoi jo olettaa, valikoituu Wintersin malli lähes kaikkien virhemallien perusteella suurimmalle osalle nimikkeistä. Ainoastaan sMAPE virhemallilla tarkimmaksi valikoituu eksponentiaalinen tasoitus jopa 63 %:lle nimikkeistä. Taulukot 10 ja 11 vahvistavat jo kuukausiennustamisessa havaittua ilmiötä, siitä, että datan manipulointi ja kausiluonteisten mallien käyttäminen tuottavat tarkempia ennusteita verrattuna muihin malleihin. Naiivimalli tuottaa jälleen tarkimman arvon suu-  
relle osalle nimikkeistä, mutta on syytä huomioda, että se valikoituu malliksi myös, jos se toimii yhtä hyvin kuin jokin toinen malli.

Vuosikohtainen ennustaminen suoritetaan hieman kuukausi- ja kvartaaliennusteista poiketen. Tarkasteluajanjaksoa pidennetään alkupäästä vuoteen 2014, jolloin malleilla on enemmän aikaa sopeutua dataan. Tutkittavat mallit ovat samat, mutta liukuvan keskiarvon mallissa käytetään vain 3 edellistä vuotta. Ennustemallit, pois lukien kausiluonteiset,

testataan suoraan historialliseen dataan siten, että ennuste simuloidaan kolmelle viime vuodelle. Mallien virhearvot lasketaan kuten kuukausi- ja kvartaaliennusteissa.

Kausiluonteisuuden löytämiseksi hyödynnetään varastonimikkeiden kategorisointia luvusta 4.3.2. Vuosikohtaisessa kausiluonteisessa ennustamisessa lähdetään liikkeelle projektin kokonaiskulutuksen ennustamisesta. Kun ensin ennustetaan koko projektin kulutus nimikkeille, voidaan tämä jakaa jokaiselle vuodelle kohdistuvaksi kulutukseksi. Projektikohtainen ennuste määritetään sekä liukuvan keskiarvon että painotetun liukuvan keskiarvon avulla. Molemmissa malleissa hyödynnetään 3 aikaisempaa projektia. Koska projektit voivat olla käynnissä jopa kolmena vuotena, pitää projektikohtainen ennuste vielä pystyä jakamaan jokaiselle kalenterivuodelle kohdistuvaksi kysynnäksi.

Tämä tehdään materiaalityhmien avulla. Jokaiselle materiaalityhmälle lasketaan aikaisempien projektien avulla keskiarvo kuukausikohtaiselle osuudelle projektin kokonaiskulutuksesta. Yksittäisen nimikkeen ennustettu projektikohtainen kulutus jaetaan eri kuukausille näiden osuuksien mukaan. Projektien aikataulujen mukaisesti ennusteet summataan kalenterikuukausille. Näin saadaan kuukausikohtainen kulutus, joka voidaan kohdistaa eri kalenterivuosille. Tässä mallissa oletetaan, että materiaalityhmien sisällä nimikkeet kuluvat projektin aikataulun suhteen suunnilleen samalla tavalla. Jakamalla projektikohtainen ennuste ryhmäkohtaisella jakaumalla yli projektiaikataulun saadaan mallinnettua tulevaa kysyntää.

Kolmantena kausiluonteisen ennustemallin avulla tutkitaan osaluettelodatan paikkansapitävyyttä ja hyödyntämistä ennustamisessa. Projektikohtainen ennuste luodaan kolmannessa kausiluonteisessa mallissa osaluettelodataan pohjautuen. Jokaiselle nimikkeelle lasketaan aikaisempien projektien avulla osaluettelokerroin, joka kertoo paljonko keskimäärin osaluetteloon tehdyt merkinnät poikkeavat todellisesta kysynnästä. Kerrointa hyödynnetään projektien kysynnän ennustamisessa. Ennuste luodaan yksinkertaisesti projektin osaluettelovarauksien ja kertoimen avulla. Ennustetun kysynnän jakaminen eri vuosille tehdään kuten muissa kausiluonteisissa malleissa. Liukuvien keskiarvojen malleissa hyödynnetään 3 aikaisemman jakson arvoja. Vuosikohtaisten ennustemallien vertailu eri virhemallien avulla on esitetty taulukossa 12.

**Taulukko 12.** Vuosiennustemallien vertailu eri virhearvojen avulla.

Virhemalli Ennustemalli	MAE	MSE	RMSE	MPE	MAPE	sMAPE
<b>Naiivi</b>	1028.30	250796909.90	1441.57	-2.36	2.80	1.92
<b>Random walk</b>	1069.70	267225066.83	1491.88	-2.78	3.17	2.19
<b>Keskiarvo</b>	1200.03	457726086.75	1603.54	-3.03	3.60	2.25
<b>Liukuva 3</b>	1209.43	426741296.57	1598.22	-3.46	3.98	2.22
<b>P.liukuva</b>	1163.54	360752990.04	1543.96	-3.29	3.78	2.20
<b>Eks.</b>	1186.17	483629553.96	1582.13	-2.95	3.48	2.23
<b>Holt</b>	1507.85	609602950.75	1912.05	-5.01	5.26	2.27
<b>Croston</b>	1275.00	671391592.52	1684.69	-2.77	3.39	3.43
<b>SBA</b>	1305.69	690306612.16	1692.39	-1.74	2.48	3.47
<b>TSB</b>	1310.16	809826897.46	1715.41	-2.69	3.34	3.49
<b>Liukuva S</b>	1329.87	670636258.51	1778.53	-1.57	2.26	2.19
<b>Osaluettelo</b>	1436.15	1237222628.06	1825.95	-0.49	1.27	2.33
<b>P.liukuva S</b>	1278.57	564365240.84	1757.57	-1.05	1.92	2.24

Taulukosta huomataan, että parhaiten toimivat Naiivimalli sekä Osaluettelomalli. Taulukossa on huomioitu kaikki varastonimikkeet, joihin sisältyvät myös uudet nimikkeet, joilla on vain vähän historiadataa. Taulukosta huomataan jälleen, että ennustamisen tarkkuus pienenee, kun ennustettava aikaväli pitenee. Taulukon 12 mukainen mallien vertailu viittaa siihen, ettei vuositason nimikkeiden kulutuksessa ole kovinkaan paljon eroa. Tällaisessa tapauksessa yksinkertaiset mallit toimivat hyvin.

Taulukossa 13 on esitetty vuosiennustemallien valinta nimikkeille, jotka ovat olleet käytössä jo ennen harmonisointia.

**Taulukko 13.** Vuosiennustemallien valinta eri virhemallien avulla jo aiemmin käytössä olleille nimikkeille.

Virhemalli Ennustemalli	MAE	MSE	RMSE	MPE	MAPE	sMAPE
<b>Naiivi</b>	946	514	516	0	171	1388
<b>Random walk</b>	276	223	225	139	124	402
<b>Keskiarvo</b>	169	237	239	3	71	228
<b>Liukuva 3</b>	125	125	127	6	72	185
<b>P.liukuva</b>	102	45	47	0	81	180
<b>Eks.</b>	66	17	19	0	41	82
<b>Holt</b>	159	171	173	1717	120	511
<b>Croston</b>	717	751	753	40	337	607
<b>SBA</b>	555	857	859	0	296	300
<b>TSB</b>	60	113	113	0	39	93
<b>Liukuva S</b>	671	653	653	316	379	727
<b>Osaluettelo</b>	1625	1677	1677	197	546	1072
<b>P.liukuva S</b>	437	525	525	0	141	133
<b>Ei sovi</b>	0	0	0	3490	3490	0
<b>Yhteensä</b>	5908	5908	5926	5908	5908	5908

Taulukosta 13 huomataan, että osaluettelodatan hyödyntämisellä on merkittävä vaikutus ennusteiden tarkkuudelle. Suurimmalle osalle nimikkeistä valikoituu juurikin osaluettelodataa hyödyntävä malli. Toisaalta myös Naiivimalli ja Crostonin malli valikoituvat usealle nimikkeelle riippuen käytettävästä virhemallista. Taulukossa 13 on esitetty vain jo ennen harmonisointia käytössä olleet nimikkeet.

#### 4.4.3 Uusien nimikkeiden ennustaminen

Uusien nimikkeiden ennustaminen aiheuttaa merkittävän ongelman kohdeyrityksen varastonhallinnalle. Kuten harmonisoinnin jälkeen huomattiin, varautuminen uusien nimikkeiden kysyntään on erittäin vaikeaa. Uusilla nimikkeillä ei ole lainkaan kysyntähistoriaa,

johon perustuen voitaisiin arvioida seuraavien projektien kulutusta. Uusien nimikkeiden kysyntä pitäisi pystyä arvioimaan jollain muulla tavalla.

Uusien nimikkeiden kysynnän arvioimisen eräs merkittävä keino on asiantuntija-arviot. Teknisillä asiantuntijoilla, systeemivastuullisilla tai suunnittelijoilla saattaa olla tietoa projektiin tai projektin osakokonaisuuteen tarvittavista määristä. Heillä saattaa myös olla tietoa uusien nimikkeiden tarveajankohdasta projektissa. Projektikohtaisen määrän ja tarveajankohdan avulla pystytään varautumaan suhteellisen hyvin tulevaan kysyntään, kun muistetaan, että kysyntä saattaa esiintyä hyvissä ajoin ennen todellista tarveajankohtaa.

Jossain tapauksissa uudet nimikkeet korvaavat vanhat nimikkeet, jolloin on luonnollista olettaa, että kysyntähistoriaa voidaan hyödyntää myös uuden nimikkeen kohdalla. Tämäkin vaatii toisaalta asiantuntijoiden arvioita muun muassa siitä, onko uusi nimike riittävästi samanlainen teknisiltä ominaisuuksiltaan, että tuleva tarve noudattaa vanhan nimikkeen tarvetta. Tämän lisäksi tarvitaan asiantuntijoiden arvioita uuden nimikkeen kaupallisista ominaisuuksista kuten hinnasta suhteessa vanhaan nimikkeeseen ja teknisiin ominaisuuksiin, toimitusajasta, eräkoista ja toimittajista. Näiden avulla pystytään varautumaan tulevaan kysyntään ja täyttämään se ilman, että palveluaste laskee merkittävästi.

Joitain keinoja myös uusien nimikkeiden tilastolliseen ennustamiseen löytyy. Kohdeyrityksen projektikohtaisen osaluettelon avulla on mahdollista arvioida kysyntää, mutta tähän liittyy alkutilanneanalyysissä esiteltyjä ongelmia. Toinen vaihtoehto on mallintaa kysyntää nimikkeiden kategorisoinnin avulla. Kuten vuosikohtaisessa ennustamisessa esiteltiin, pystytään materiaalityhmille laskemaan projektikohtainen kysyntäjakauma. Tämän jakauman avulla pystytään arvioimaan kulutusta, kun uudelle nimikkeelle arvioidaan ensin projektikohtainen kokonaisennuste. Tämä kokonaisennuste saadaan laskettua jakauman ja jo ilmaantuneen kysynnän avulla. Tämä kirjoittajan johtama **Materiaalityhmämalli** voidaan esittää muodossa:

$$Y_t = \frac{\sum_{i=1}^{t-1} A_i}{\frac{\sum_{i=1}^{t-1} A_{R,i}}{\sum_{i=1}^L A_{R,i}}} * \frac{\sum_{i=1}^t A_{R,i}}{\sum_{i=1}^L A_{R,i}} - \sum_{i=1}^{t-1} A_i, \quad (46)$$

jossa

$Y_t$  = ennuste seuraavalle aikajaksolle

$A_i$  = toteutunut kysyntä

$A_{R,i}$  = materiaalityhmän toteutunut keskimääräinen kysyntä

$L$  = projektin pituus kuukausina.

Tässä mallissa oletetaan, että uusi nimike käyttäytyy jokseenkin samalla tavalla kuin saman materiaaliryhmän nimikkeet keskimäärin. Mallissa ennustetta päivitetään tarkemmaksi, kun uusia kysyntöjä ilmaantuu. Malli antaa vain karkean arvion tulevasta kysynnästä pohjautuen saman tyyppisten nimikkeiden historialliseen kysyntään. Todellisuudessa uuden nimikkeen kysyntä saattaa erota muista ryhmän nimikkeistä.

Taulukossa 14 on esitetty mallien valinta uusille nimikkeille kuukausikohtaisessa ennustamisessa eri virhemallien avulla.

**Taulukko 14.** Kuukausiennustemallien valinta uusille nimikkeille eri virhemallien avulla.

<b>Virhemalli</b> <b>Ennustemalli</b>	<b>MAE</b>	<b>MSE</b>	<b>RMSE</b>	<b>MPE</b>	<b>MAPE</b>	<b>sMAPE</b>
<b>Naiivi</b>	645	367	367	0	15	483
<b>Random walk</b>	112	144	144	91	6	0
<b>Keskiarvo</b>	1005	68	68	0	24	0
<b>Liukuva 3+5</b>	202	372	372	3	25	0
<b>P.liukuva</b>	32	28	28	0	8	0
<b>Eks.</b>	167	295	295	0	50	830
<b>Holt</b>	231	343	343	34	25	2417
<b>Croston</b>	652	992	992	0	15	19
<b>SBA</b>	78	233	233	0	28	18
<b>TSB</b>	76	142	142	0	16	50
<b>Mat. Ryhmä-malli</b>	809	1025	1025	120	24	192
<b>Ei sovi</b>	0	0	0	3761	3773	0
<b>Yhteensä</b>	4009	4009	4009	4009	4009	4009

Taulukon 14 mukaan uusien nimikkeiden ennustamiseen kehitelty materiaaliryhmäkategorisointia hyödyntävä malli tuottaa jossain määrin luotettavia ennusteita. Yksiselitteisesti se ei valikoidu nimikkeille tarkimmaksi ennusteeksi, mutta tiettyjen virhemallien mukaan kuitenkin suurimmalle osalle. Uusille nimikkeille taulukon 14 mukaan soveltuvat tämän lisäksi tarkimmin Keskiarvomalli sekä Holtin malli.

Tulososiossa käytettyjen mallien optimoimisessa käytettiin sovitusegmentin lisäksi sekä kokeilevaa analysointia että Microsoft Excelin Ratkaisin –sovellusta. Näiden avulla määritettiin painotus- ja tasoituskertoimet sekä optimoitiin mallit tuottamaan mahdollisimman

tarkkoja ennusteita. Painotetun liukuvan keskiarvon mallissa käytettiin 4:ää edellistä aikaväliä ja näille painokertoimia 0,1; 0,2; 0,3 ja 0,4. Liukuvan keskiarvon mallissa ennusteet puolestaan laskettiin 3 ja 5 aikaisemman aikavälin avulla. Muissa malleissa hyödynetyt tasoituskertoimet on esitetty taulukossa 15.

**Taulukko 15.** Ennustusmalleissa käytetyt tasoituskertoimet.

	$\alpha$	$\beta$	$\gamma$
<b>Eks.</b>	0.05...0.35	-	-
<b>Holt</b>	0.15...0.56	0.07...0.25	-
<b>Croston</b>	0.10...0.25	0.15...0.40	-
<b>SBA</b>	0.15...0.56	0.15...0.40	-
<b>TSB</b>	0.20...0.40	0.15...0.60	-
<b>Winters</b>	0.25...0.62	0...0.15	0.20...0.83

Taulukossa 15 on esitetty käytettyjen tasoituskertoimien vaihteluvälit. Malleissa hyödynnettiin useampia eri kertoimia ja kerroinyhdistelmiä, jotta saatiin esille mahdollisimman tarkat ennusteet eri aikaväleille ja nimikkeille.

## 4.5 Ennusteen luominen

Kohdeyrityksen tapauksessa ennusteen luominen voidaan jaotella käytännössä kahteen erilaiseen tilanteeseen. Ensimmäinen liittyy lyhyen aikavälin ennustamiseen, jolla pyritään ylläpitämään nimikkeiden varastotasot riittävän korkealla. Näin varmistetaan, että tuotannolla ja alihankkijoilla on saatavilla tarvittavat nimikkeet. Tähän vastaa kuukausi- ja kvartaaliennustaminen. Toinen tilanne liittyy nimikkeiden saatavuuteen toimittajilta. Vuosiennusteilla varmistetaan nimikkeiden saatavuus valmistajilta ja toimittajilta pidemmälle aikaväleille. Näiden ennusteiden avulla pystytään varmistamaan, että tarvittavat varastotasot pystytään ylläpitämään lyhyellä aikavälillä. Koko vuoden tarvittavia nimikkeitä ei ole taloudellisesti kannattavaa varastoida, mutta valmistajat ja toimittajat tarvitsevat kuitenkin pitkän aikavälin ennusteita varautuakseen kysyntään.

Käytännön ennustamiseen on useita eri vaihtoehtoja. Nimikkeiden kysyntään varautuminen ja sen ennakoiminen on mahdollista suorittaa kuten tähänkin asti, mutta tämän tyyppinen reaktiivinen varastonhallinta on taloudellisesti kannattamatonta ja varaston palveluaste kärsii merkittävästi. Toinen vaihtoehto on manuaalinen ennusteiden laskeminen ja arvioiminen, minkä perusteella kysyntään pystyttäisiin varautumaan. Nimikkei-

den suuren määrän takia tämä vaihtoehto on kuitenkin hyvin kallista toteuttaa. Kohdeyrityksen toiminnan kannalta merkittävin vaihtoehto liittyykin ennustamisen automatisointiin ja ennustusjärjestelmän hyödyntämiseen osana varastonhallintaa.

Osana tutkimusta selvitettiin erilaisten ennustusjärjestelmien soveltuvuus kohdeyrityksen varastonimikkeiden kysynnän ennustamiseen. Selvityksessä tutkittiin erityyppisiä ratkaisuja osana ennustamista. Ennustamisessa on mahdollista hyödyntää järjestelmää, joka tarjoaa vain työkalun ennusteen luomiseen osana jotain toista tietojärjestelmää kuten Microsoft Exceliä tai toiminnanohjausjärjestelmää. Toinen vaihtoehto on itsenäinen järjestelmä, joka suorittaa datan analysoinnin ja ennustamisen itsenäisesti. Kolmas tutkittava järjestelmätyyppi liittyi täysin uuden järjestelmän rakentamiseen kohdeyrityksen tarpeiden mukaisesti. Tämä vaihtoehto käsittää lähinnä Microsoft Excel –pohjaisen ratkaisun kehittämisen.

Selvityksessä huomattiin, että valmiit järjestelmät poikkeavat jonkin verran kohdeyrityksen asettamista vaatimuksista ja tarpeista. Järjestelmät eivät ole suunniteltuja projektiliiketoimintaan vaan tasaisen kysynnän tilanteisiin, joissa järjestelmien tuoma etu liittyy automatisaatioon ja suureen laskentatehoon, kun nimikkeitä on suuri määrä. Useat järjestelmät pystyvät optimoimaan käytettävät mallit ja valitsemaan kunkin nimikkeen kohdalle parhaimman mallin historiadatan avulla. Tutkittujen järjestelmien merkittävimmät eroavaisuudet liittyivät järjestelmän ominaisuuksiin sopeutua kohdeyrityksen tilanteeseen.

Kohdeyrityksen varastonimikkeiden ennusteiden luomisessa on tämän tutkimuksen mukaan syytä ottaa huomioon tiettyjä ominaisuuksia. Tällaisia tekijöitä ovat varsinkin

- kysynnän epätasaisuus
- useiden ennustemallien hyödyntäminen
- usean aikavälin ennustaminen
- datan manipulointi
- uusien ennustemallien luominen
- useiden datatyyppeiden hyödyntäminen
- ennustamisen automatisointi.

Kysynnän epätasaisuus on havaittavissa luvussa 4.3.2 tehdyssä nimikkeistön kategorisoinnissa. Vain pieni osa nimikkeistä on tasaisesti kuluvia, mikä asettaa haasteen ennustusjärjestelmille. Lähes kaikki valmiit järjestelmät on tarkoitettu tasaisen kysynnän tuotteille. Kuten luvusta 4.4 huomataan ei yksi yksittäinen malli toimi paremmin kuin muut



mallit, mikä asettaa vaatimuksen useiden eri ennustusmallien käyttämiselle. Valmiissa järjestelmissä on suhteellisen hyvin hyödynnettävissä tässä tutkimuksessa käytetyt mallit. Myöskään useamman aikavälin ennustaminen ei tuota ongelmia järjestelmille.

Datan manipulointi taas rajoittaa merkittävästi järjestelmien sopivuutta. Tutkimuksessa havaittiin, että kausiluonteisuuden huomioiminen ja kysyntähistoriadatan jakaminen projekteille sekä näiden ennustaminen erikseen parantaa merkittävästi ennustamisen tarkkuutta. Datan manipulointi voitaisiin suorittaa myös ennustusjärjestelmän ulkopuolella, mikä monimutkaistaa ennustusprosessia ja toisaalta kyseenalaistaa ennustusjärjestelmän tarpeellisuuden. Myös uusien ennustusmallien luominen on haaste järjestelmille. Uusien mallien luominen on kuitenkin tämän tutkimuksen mukaan tärkeää luotettavien ennusteiden saamisessa. Kuten vuosiennustamisen ja uusien nimikkeiden tilanteessa huomattiin, tuottavat kokonaan uudet ennustemallit tarkkoja ennusteita merkittävälle määrälle nimikkeitä.

Uusien mallien luomiseen liittyy myös ominaisuus useiden erilaisten datatyypin hyödyntämisestä. Osaluettelodata ja materiaaliyhmäkohtaisen datan hyödyntäminen vaativat järjestelmältä ketteryyttä ja toisaalta myös mahdollisuutta räätälöidä ennustemallit tai datan manipulointi sellaiseksi, että useat eri datatypit pystytään huomioimaan. Ennustamisen automatisointi liittyy puolestaan järjestelmän ominaisuuteen laskea ennusteet kaikille tarvittaville nimikkeille. Kohdeyrityksen tilanteessa tämä tarkoittaa yli 10 000 nimikettä, joille ennusteet tarvitaan. Manuaalinen ennusteiden luominen kaikille näille nimikkeille ei olisi järkevää.

Ennustamisen järjestelmän valinnan kannalta merkittävimmiksi tekijöiksi muodostuvat datan manipulointi ja uusien ennustemallien luominen. Kohdeyrityksen tilanteeseen sopii parhaiten järjestelmä, joka on räätälöitävissä projektiliiketoimintaan sopivaksi. Yllä mainitut vaatimukset täyttäviä järjestelmiä on tarjolla hyvin rajatusti. Suurin osa järjestelmistä on tarkoitettu tasaisen kysynnän tilanteisiin, joissa ennusteita hyödynnetään enemmän varastotasojen optimoimiseen ja tilauksien hallintaan. Tämän tyyppiset tilanteet eivät vaadi järjestelmältä ennusteiden luomisen suhteen monimutkaisia malleja tai prosesseja, vaan järjestelmän hyöty tulee kokonaisvaltaisemmasta varastonhallinnasta.

Ennustamiseen käytettävässä järjestelmässä on myös huomioitava uusien nimikkeiden ennustaminen. Kuten luvussa 5.5.3 todetaan, parhaiten tämä onnistuu mahdollisuutena oikaista ennusteita kvalitatiivisesti. Varsinkin uusien nimikkeiden kohdalla, kun nimikkeillä ei vielä ole historiadataa, toimivat kvalitatiiviset ennustusmenetelmät parhaiten. Toisaalta luvussa 4.4.3 luotu Materiaaliyhmämalli toimii suhteellisen hyvin nimikkeiden kysynnän ennustamisessa.

Tutkimuksen pohjalta suositellaan hyödyntämään ennustamisessa joko järjestelmää, joka on vahvasti räätälöitävissä kohdeyrityksen tilanteen vaatimiin ominaisuuksiin tai kokonaan uuden ennustusjärjestelmän luomista. Uuden järjestelmän luominen vaatii enemmän resursseja ja aikaa, jotta se saadaan toimimaan halutulla tavalla ja automatisoidusti. Valmiiden järjestelmien etu on myös käyttäjäystävällisyys, joka osaltaan luo ennusteiden merkitystä ja käyttöönottoa osana varastonhallintaa.

#### **4.5.1 Kvalitatiivinen oikaisu**

Kvalitatiivinen oikaisu näyttelee merkittävää osaa lopullisten ennusteiden luomisessa. Varsinkin pidemmän aikavälin ennustamisessa kvalitatiiviset oikaisut ovat tärkeässä roolissa, kun nimikkeiden kysyntään liittyy paljon epävarmuutta ja tekijöitä, jotka voivat vaikuttaa kysynnän määrään. Esimerkiksi päätökset suunnittelussa tai projektikohtaiset vaatimukset käytettävistä nimikkeistä voivat vaikuttaa kysyntään merkittävästi. Tämänkaltaisen tieto on usein hajautunut ja sitä ei ole tallennettu järjestelmiin. Teknisillä asiantuntijoilla ja suunnittelijoilla on hiljaista tietoa projekteissa tarvittavista nimikkeistä.

Lopullisen ennusteen luomisessa onkin hyvä huomioida aina kvalitatiivinen komponentti. Kohdeyrityksen tilanteessa asiantuntija-arvioilla pystytään oikaisemaan ennusteita, jos asiantuntijoilla on tarkempi näkemys kysyntään vaikuttavista tekijöistä. Kaikki tekijät eivät näy historiadatassa, vaan lopulliset ennusteet voivat olla monen eri tekijän summa. Tietyt nimikkeet tai tuotekategoriat voivat käyttäytyä eri projekteissa eri tavoin. On myös mahdollista, ettei tiettyjä nimikkeitä käytetä ollenkaan yksittäisessä projektissa. Ainoastaan historiadataan pohjautuvassa ennustamisessa ei lopullinen ennuste ota huomioon projektin suunnittelua tai asiakkaan tarpeita. Kvalitatiivisilla oikaisulla pystytään kuitenkin parantamaan nimikkeiden ennustustarkkuutta.

### **4.6 Ennusteen käyttäminen ja tarkkuuden mittaaminen**

Varastonimikkeiden kysynnän ennusteita tarvitaan ja käytetään kohdeyrityksen osalta muutamassa erilaisessa tilanteessa. Kuten luvussa 4.5 todetaan, ennusteita käytetään sekä lyhyen aikavälin kysynnän täyttämiseen että pidemmällä aikavälillä tuotantokapasiteetin varmistamiseen toimittajien ja valmistajien suunnalta. Nimikkeiden suhteellisen lyhyiden toimitusaikojen takia pidemmän aikavälin ennusteita ei niinkään tarvita varastotasojen ylläpitämiseen, vaan lyhyemmän aikavälin ennusteilla pystytään varautumaan tuotannon ja alihankkijoiden materiaalitarpeisiin.

Ennusteiden käyttämisessä on huomioitava tiettyjä asioita, joiden avulla ennusteita pystytään hyödyntämään mahdollisimman tehokkaasti. Ennusteen käyttäjän on hyvä ymmärtää mistä ennusteet syntyvät, ja toisaalta mitä rajoitteita niillä on. Kuten aiemmin todettiin, tilastolliset ennusteet pohjautuvat pääsääntöisesti historialliseen dataan, joka ei kerro koko totuutta tulevasta kysynnästä. Projektiliiketoiminnalle ominaisesti jokainen projekti on erilainen, milloin myös varastotuotteiden kulutus ja tarpeet eri projekteissa vaihtelevat.

Ennusteiden käyttämisessä on hyvä huomioida myös kvalitatiivinen oikaisu, jonka usein tekevät myös ennusteiden käyttäjät. Vaikka systemaattisella tilastollisella ennustamisella pyritään poistamaan aikaisemmat perinteet pelkkien asiantuntija-arvioiden käytöstä, ovat ne kuitenkin tärkeitä lopullisen ennusteen muodostamisessa. Asiantuntija-arvioita tarvitaan varsinkin pidemmän aikavälin ennusteiden oikaisuissa. Jotta kvalitatiivisia ennusteita voidaan käyttää, pitää tarkkaan määritellyt henkilöt olla osana ennustusprosessia.

Ennusteiden raportointi on merkittävässä roolissa niiden käyttämisen kannalta. Ennusteiden pitää olla helposti saatavilla, mikä edesauttaa niiden hyödyntämistä osana varastonhallintaa. Järjestelmän pitää olla riittävän yksinkertainen, ettei sen käyttämisestä ja käyttöönotosta koidu liian suurta estettä. Ennusteiden käyttäjillä on hyvä olla jatkuva pääsy järjestelmään ja ennusteisiin, mikä parantaa ennusteiden käyttöastetta ja toisaalta luottamusta ennusteiden paikkansapitävyyteen ja ajantasaisuuteen. Ennustusjärjestelmän tuottamat raportit on hyvä pitää yksinkertaisina, mutta riittävän kattavina, jotta ennusteiden käyttäjillä on tarvittava tieto käytössään.

Ennusteiden raportoinnissa pitää olla näkyvillä eri ennustettavat aikavälit kuukausi, kvartaali ja vuositasolla. Tämän lisäksi on hyvä esittää projektikohtainen ennuste, joka lisää ennusteen läpinäkyvyyttä ja toisaalta luottamusta ennusteiden laatuun. Raportoinnissa on hyvä myös esittää jo toteutuneita arvoja nykyhetkestä taaksepäin. Muutaman aikavälin esittäminen ennusteiden käyttäjille lisää luottamusta ennusteisiin, kun ymmärretään paremmin mistä ennuste rakentuu.

Riittävän usein päivittyvät ennusteet, jotka on helppo saada ja toisaalta ymmärtää, määrittelevät laadukkuudellaan lopullisen käytettävyyden. Tutkimuksen valossa ennusteiden päivittämiseen riittää päivittäinen tai jopa viikoittainen päivitysväli, jolloin historiallinen data ja ennusteet päivitetään vastaamaan todellisia arvoja. Päivitys voi tapahtua joko automatisoidusti tai manuaalisesti riippuen päivitysvälistä ja järjestelmien ketteryydestä. Historiadatan lähde ja ennustusjärjestelmä pitää pystyä integroimaan, siten että datan tuonti on mahdollisimman yksinkertaista eri järjestelmien välillä.

Uuden ennustusprosessin käyttöönotto vaatii myös muutosjohtamista ja kouluttamista. Ennustamiseen käytettävän järjestelmän käyttäminen vaatii ennusteiden käyttäjien kouluttamista, jotta ennustamisen prosessi saadaan mahdollisimman tehokkaaksi. Aiemmin käytetyistä prosesseista ja toimintatavoista luopuminen vaatii myös sitoutumista. Kohdeyrityksen tilanteessa on kuitenkin selvää, että aiemmin käytetyt prosessit ja toimintatavat eivät toimi haluttujen tavoitteiden mukaisesti.


Ennusteiden käyttäjät pohjaavat operatiiviset päätöksensä luotuihin ennusteisiin. Nimikkeiden saatavuus tuotannolle projektin eri vaiheissa pystytään varmistamaan ennusteiden avulla. Käyttäjien on hyvä ymmärtää, miten ennusteet luodaan, jotta heidän tekemänsä päätökset eivät kärsi käyttäjän omien arvioiden vinoutuneisuudesta. Ennusteiden avulla pystytään helpottamaan huomattavasti varastonhallinnan päätöksiä tilauseristä sekä tilaushetkistä. Näiden avulla taataan, ettei varaston arvo kasva turhan suureksi ottaen kuitenkin huomioon, että tuotanto saa tarvittavat nimikkeet riittävän ajoissa.

Ennusteen tarkkuutta on mitattava säännöllisesti. Tutkimuksen mukaan tarkkuuden mittaamiseen on hyvä käyttää joko MAE, MSE tai RMSE mallia, koska suhteelliset mallit eivät toimi epäsäännöllisen kysynnän luonteen takia kovinkaan hyvin. Ennusteen tarkkuuden säännöllisen mittaamisen avulla pystytään kiinnittämään huomiota sellaisiin nimikkeisiin, joiden kysyntä on oleellisesti muuttunut aiemmasta tai joiden kysynnän luonteen takia ennustaminen on erityisen hankalaa. Tällaiset nimikkeet saattavat vaatia tietyn tyyppisen ennustemallin tai enemmän huomiota kvalitatiiviselle ennustamiselle.

Ennustamisen raportoinnissa on hyvä esittää myös toteutuneiden arvojen ja ennusteen avulla mitattu ennusteen virhe  $e_t$ . Tämän avulla ennusteiden käyttäjä näkee suoraan ennusteiden toimivuuden ja toisaalta ymmärtää paremmin, etteivät ennusteet ole absoluuttisen oikeita ja sisältävät aina virheen. Toisaalta tästä näkee helposti tietyn nimikkeen ennusteen käyttäytymisen. Esimerkiksi, jos ennusteet ovat säännöllisesti vinoutuneita, on mahdollista tehdä kvalitatiivisia oikaisuja, jotka parantavat ennusteen tarkkuutta. Ennusteen tarkkuutta virhemallien avulla ei tarvitse raportoinnissa esittää, mutta sen säännöllinen seuraaminen ja ennustemallien optimoiminen virheiden avulla on kuitenkin tärkeä osa ennustamista.

## 4.7 Kohdeyrityksen ennustusprosessi

Tämän tutkimuksen avulla kohdeyrityksen ennustusprosessille voidaan muodostaa karkealuonteinen teoreettinen viitekehys. Tämä prosessi muistuttaa aiemmin teoriaosiossa esiteltyä ennustusprosessia, jonka pohjalta osittain tutkimuksen empiirinen osiokin suoritettiin. Ennustusprosessi on esitetty kuvassa 7



**Kuva 7.** Kohdeyrityksen karkealuonteinen viitekehys ennustusprosessille.

Kuvassa 6 esitetty viitekehys ennustusprosessille kohdeyrityksen tilanteessa on päivitetty versio teoriaosiossa esitellystä Sandersin viitekehyksestä. Ennustusprosessi lähtee liikkeelle **ennustamisen tarpeen määrittelystä**. Tämä vaihe on tärkeä koko ennustusprosessin määrittelyn kannalta. Jos ennustamisen todellista tarvetta ei tunnisteta, koko prosessin tehokkuus ja laadukkuus kärsivät. Tarpeen määrittely on hyvä myös sisällyttää ennustusprosessin iteratiiviseen luonteeseen, mikä tarkoittaa, että ennustamisen tarve on hyvä päivittää ennustamisen tulosten ja kohdeyrityksen tarpeiden mukaisesti. Esimerkiksi nimikeluettelon päivittymisen myötä ennustamisen kohde muuttuu ja tarve määrittelyn muuttamiselle pitää selvittää. Toisaalta muutokset esimerkiksi toimitusketjussa tai varastohallinnassa voivat muuttaa ennustamisen tarvetta.

Kuvan 6 ennustusprosessissa on jaoteltu erilleen **datan kerääminen**. Kohdeyrityksen tilanteessa data pitää kerätä useasta eri tietolähteestä, jolloin datan integrointi ennustusjärjestelmään vaatii enemmän huomiota. Datan kerääminen on myös hyvä saada automatisoitua siten, ettei datan päivittäminen tai kerääminen vaadi liikaa resursseja. Data voidaan päivittää reaaliajassa tai maksimissaan viikon mittaisissa päivityksissä riippuen ennustusjärjestelmän ominaisuuksista. Datan keräämisen jälkeen suoritetaan **datan puhdistus**, jossa data manipuloidaan ja kohdistetaan projektikohtaisiksi kysynnöiksi. Tämän lisäksi historiadataa korjataan virheellisten arvojen osalta.

**Datan analysointivaiheessa** tunnistetaan historiadatasta kysynnän eri komponentit trendi, melu, syklisyys ja kausivaihtelu. Tässä vaiheessa myös jaotellaan nimikkeet uusiin ja vanhoihin tuotteisiin, koska näiden kahdentyyppisen nimikkeen ennustaminen eroaa huomattavasti. Tietyillä raja-arvoilla voidaan määrittää, milloin nimike lasketaan vanhaksi nimikkeeksi. Tällöin ennusteen luomisessa painotetaan historiadataa. Projektiliiketoiminnan takia tarvitaan vähintään yhden aiemman projektin verran kysyntähistoriaa kohdeyrityksen tilanteessa, jotta tilastollisella ennusteella on riittävästi perustaa. Datan analysoinnin avulla suoritetaan **ennustusmallin valinta**. Ennustusjärjestelmästä riippuen voidaan hyödyntää automaattista mallin valintaa tai käyttää tämän luvun tuloksia tarkimmista malleista.

**Ennusteen luomisessa** ennuste lasketaan aiempien vaiheiden avulla. Luomisessa otetaan huomioon kvalitatiivinen oikaisu, jonka avulla ennustetta parannetaan. Ennusteen luominen suoritetaan valittavalla ennustusjärjestelmällä, joka kykenee datan automaattiseen keräämiseen, manipulointiin, analysointiin ja ennustemallin valintaan. Ennustusjärjestelmä esittää luodut ennusteet, jotka välitetään ennusteiden käyttäjille. **Ennusteiden käyttövaiheessa** ennusteiden käyttäjät pohjaavat päätöksensä luotuihin ennusteisiin ja varmistavat nimikkeiden saatavuuden tuotannolle. Varastotasojen hallinnalla sekä

tilauskokojen ja –hetkien optimoimisella pystytään vastaamaan tulevaan kysyntään jo ennen kysynnän ilmaantumista.

**Ennusteen tarkkuuden mittaamisella** varmistetaan ennustusmallien ja -järjestelmän toimivuus. Tarkkuuden mittaamisella pystytään kiinnittämään huomiota vaikeasti ennustettaviin nimikkeisiin tai nimikkeisiin, joiden kysyntä muuttuu siten, että ne vaativat enemmän manuaalista ennustamista. Tarkkuuden mittaamisella pystytään tiettyjen nimikkeiden osalta palaamaan prosessin aiempiin vaiheisiin, ja parantamaan ennustustarkkuutta esimerkiksi datan manipuloinnilla, analysoinnilla tai mallin valinnalla. Tarkkuuden mittaamisella pystytään myös validoimaan koko ennustusprosessin toimivuus ja kehittämään koko prosessia.

Poiketen teoriaosiossa esitellystä ennustusprosessista, kohdeyrityksen ennustusprosessin iteratiivisuus sisältää kaikki prosessin vaiheet. Tarkkuuden mittaamisella otetaan kantaa ennustamisen tarpeisiin ja ennustettaviin nimikkeisiin sekä koko ennustamisen luonteeseen. Lyhyen aikavälin iteratiivisuus näkyy puolestaan datan keräämisen ja tarkkuuden mittaamisen välillä. Säännöllinen datan kerääminen aloittaa koko ennustusprosessin uudestaan. Päivitetyt datan avulla ennustusprosessia pystytään päivittämään ja kehittämään tarkemmaksi. Tämän lisäksi prosessin iteratiivisuuden avulla varmistetaan prosessin kaikkien vaiheiden huomioiminen osana prosessia ja näiden kehittäminen tehokkaamman ja laadukkaamman prosessin saavuttamiseksi.

## 5. PÄÄTELMÄT JA JATKOTOIMENPITEET

### 5.1 Tutkimuksen keskeisimmät tulokset

Tutkimuksen mukaan kohdeyrityksen **varastomateriaalien kysyntä on hyvin ennustettavissa**. Ennustamisessa on kuitenkin otettava tiettyjä ominaisuuksia huomioon ennustustarkkuuden varmistamiseksi. Tutkimuksen mukaan kysyntä on suurimmalle osalle varastomateriaaleista hyvin epäsäännöllistä. Epäsäännöllisyydestä johtuen ennustettavuus kärsii. Taulukosta 3 kuitenkin huomataan, että kysynnän esiintyessä se on verrattain tasaista, joten nimikkeiden kysynnän ennustettavuutta on mahdollista parantaa, kunhan tunnetaan kysynnän esiintymisen todennäköisyys paremmin. Kysynnän esiintymisen ennustettavuutta pystytään parantamaan merkittävästi **historiadatan manipuloinnilla**.

Tutkimuksen tuloksien mukaan toteutuneen kysynnän manipulomisella on merkittävä vaikutus ennustettavuuteen. Tämä on havaittavissa kuukausi-, kvartaali- ja vuosienennusteissa. Historiakysyntä pystytään jakamaan jokaiselle projektille kohdistuvaksi kysynnäksi. Näin saadaan selville jokaisen projektin todellinen materiaalien kysyntä. Kun tämän manipuloidun kysyntähistorian avulla ennustetaan tulevat projektit erikseen, ja summataan saadut projektikohtaiset kysynnot kokonaiskysynnäksi, paranee ennustustarkkuus suurelle osalle nimikkeistä.

**Tutkimuksen tulokset myötäilevät aiempien tutkimuksien teorioita.** Kohdeyrityksen tapauksessa ennustustarkkuus pienenee selvästi, kun ennustettava aikaväli suurenee. Toisaalta huomataan, että kuten aiempien tutkimuksien tarkastelu antoi olettaa, ei ole yksiselitteistä, että monimutkaisemmat ennustemallit antaisivat tarkempia tuloksia verrattuna yksinkertaisiin. Aiempiin tutkimuksiin verrattuna tämän tutkimuksen mallien valinta on kuitenkin osittain ristiriidassa. Epäsäännöllistä kysyntää tutkittaessa on usein aiemmissa tutkimuksissa päädytty tiettyihin ennustusmalleihin tarkimpina. Tässä tutkimuksessa epäsäännöllisen kysynnän mallien valikoituminen tarkimmiksi malleiksi ei kuitenkaan ole yhtä selkeää.

Tutkimuksen yhtenä merkittävimmistä tuloksista voidaan pitää **uusien nimikkeiden ennustamisen tutkimista**. Jos uusi nimike ei korvaa jotain tiettyä toista nimikettä, milloin ennustamisessa pystytään hyödyntämään tämän historiadataa, voidaan ennustamisessa hyödyntää materiaalityhmäkohtaista dataa. Tutkimuksen yhtenä tuloksena on kaavassa (46) esitetty **uusi ennustamisen malli**, jossa hyödynnetään saman materiaalityhmän nimikkeiden samankaltaista käyttäytymistä projektien sisällä. Toisaalta yhtenä



keskeisimpänä tuloksena nähdään **osaluettelodatan hyödyntäminen** osana nimikkeiden ennustamista. Tähän liittyy kuitenkin ongelmia muun muassa osaluettelon ajoituksen osalta.

Tutkimuksessa asetetaan myös **karkeat ehdot mahdollisen ennustusjärjestelmän käyttöönotolle**. Järjestelmän on oltava räätälöitävissä datan manipuloinnin osalta ja toisaalta uusien ennustusmallien luomisen kannalta. Tämän lisäksi järjestelmän pitää pienentää ennustamiseen tarvittavien resurssien tarvetta automatisoimalla ennustamista. Tämän lisäksi ennusteiden pitää olla helposti hyödynnettävissä ja saatavissa ennusteiden käyttäjille. Tutkimuksen perusteella asetetut ehdot järjestelmälle rajaavat suuren osan kaupallisista järjestelmistä pois, mutta vaihtoehtoja kohdeyritykselle kuitenkin löytyy.

Tutkimuksen perusteella annetaan myös karkealuonteinen **viitekehys kohdeyrityksen ennustusprosessille**. Ennustusprosessin avulla voidaan suunnitella ennustusjärjestelmää hyödyntävä jatkuva toiminto, joka hyödyntää tutkimuksessa esille tuotuja huomioita. Tavoitteena on parantaa varastomateriaalien saatavuutta ja helpottaa niiden tilaamiseen sekä varastointiin liittyvää epävarmuutta. Ennustusprosessissa huomioidaan ennustamisen tarve, datan kerääminen, puhdistus ja analysointi sekä ennustemallin valinta, ennusteen luominen ja käyttäytyminen. Tämän lisäksi monitoroidaan ennusteiden tarkkuutta ja päivitetään prosessia tarpeen vaatiessa.

Kaiken kaikkiaan tutkimuksen perusteella voidaan todeta, että kohdeyrityksen nimikkeiden kysynnän **ennustamisella pystytään parantamaan lähtötilannetta**. Ennustamisella on mahdollisuus vastata kohdeyrityksen ongelmiin ja tarjota ratkaisuja materiaalien kysynnän parempaan ennakoimiseen. Ennustamisella on mahdollista parantaa palveluastetta ja varmistaa nimikkeiden oikea-aikainen saatavuus tuotannolle. Kun tuotannolla on saatavilla tarvittavat materiaalit oikeaan aikaan, ei projekteille aiheudu aikataulupaineita ja viivästyksiä. Toisaalta toimitusketjun hallinta helpottuu, kun toimittajien valmius reagoida tilauksiin paranee.

## 5.2 Suositeltavat jatkotoimenpiteet

Tutkimuksen perusteella suositellaan, että kohdeyritys lähtee toteuttamaan nimikkeiden kysynnän ennustamista osana varaston- ja toimitusketjun hallintaa. Tähän suositellaan hyödynnettäväksi ennustamisen järjestelmää, joka täyttää asetetut kriteerit. Ennustusjärjestelmän valinta ja käyttöönotto vaativat lisää tutkimusta järjestelmien ominaisuuksista, jotta valitaan kohdeyrityksen kannalta paras mahdollinen. Tämän lisäksi järjestelmän käyttöönotto vaatii paljon työtä eri järjestelmien integroimisen, ennustejärjestelmän

optimoimisen, datan saannin, henkilöstön kouluttamisen ja toimittajien osallistamisen kannalta.

Tarkan ennustusprosessin suunnittelu ja tarpeellisten työntekijöiden osallistaminen osaksi ennustamisen prosessia ovat merkittävässä roolissa suositeltavissa jatkotoimenpiteissä. Tutkimuksen perusteella suositellaan myös vahvaa yhteistyötä koko toimitusketjun osalta. Ennusteiden välittäminen toimittajille ja sidosryhmille on avainasemassa sujuvan varastonhallinnan kannalta. Paikan päällä toimivien jälleenmyyjien sisällyttäminen osaksi ennustusprosessia parantaa varastonhallintaa ja tehostaa prosessia.

Kuten aiemmin todettiin, jokaisella projektilla on oma tuoterakenne eli osaluettelo, jossa on suunniteltu projektissa tarvittavat materiaalit. Näissä osalueteloissa on kuitenkin paljon virheitä ja niiden aikataulut on usein virheellinen. Periaatteessa nimikkeiden kuluksien ennustamista ei tarvittaisi laisinkaan, jos osaluetelot olisivat täydellisiä. Tämän tutkimuksen perusteella suositellaan jatkotutkimusta osalueteloiden parantamiseksi kohdeyrityksen puolesta. Tärkeää olisi selvittää, millä keinoilla niiden parantaminen olisi mahdollista ja olisiko se taloudellisesti kannattavaa. Vaikka on selvä, että monimutkaisiin projekteihin liittyy aina epävarmuutta ja muutoksia tapahtuu projektien edetessä, osalueteloilla pystyttäisiin parantamaan nimikkeiden kysyntään varautumista.

### **5.3 Tutkimuksen arviointi**

Tutkimus vastaa sille asetettuihin tutkimusongelmiin hyvin. Tutkimukselle asetettuihin tavoitteisiin myös päästiin suhteellisen onnistuneesti. Varastonimikkeiden ennustettavuudesta ja sen vaatimuksista saadaan tutkimuksen perusteella kattava kuva. Tämän lisäksi tutkimuksen perusteella saatiin selville, mitä kaikkea pitää huomioida nimikkeiden kysynnän ennustamisessa. Tutkimuksessa myös pystyttiin antamaan karkealuonteinen viitekehys suositeltavalle ennustusprosessille ja toisaalta kartoitettiin ennustusjärjestelmien ominaisuuksia.

Tutkimuksen arvioinnissa on hyvä huomioida, että se on tapauskohtainen tutkimus, jonka tulokset soveltuvat vain kohdeyrityksen tilanteeseen. Tämän lisäksi pitää huomioida, että tutkimuksen tulokset soveltuvat vain kohdeyrityksen nykyiseen tilanteeseen, ja tutkimuksen tulokset eivät välttämättä sovellu sellaisinaan tulevaisuudessa edes kohdeyrityksen tilanteeseen. Toimintaprosessien, toimitusketjun tai projektien luonteen muutoksen takia tämän tutkimuksen tulokset eivät välttämättä ratkaise muuttuneiden tilanteiden ongelmia.

Tutkimuksessa on käytetty monipuolisesti aiempien tutkimusten teorioita ja tapauksia, joiden perusteella saatiin muodostettua kohdeyrityksen tilanteeseen sopivia johtopäätöksiä. Tällaisten johtopäätösten muodostaminen vastaa hyvin tutkimuksen alkuperäistä deduktiivista lähestymistapaa. Toisaalta tutkimus noudatti hyvin objektiivista otetta, jossa huomioidaan tilanteet, prosessit ja asiat sellaisina kuin ne ovat ja poissuljetaan ihmisten vaikutukset näihin. On kuitenkin syytä huomioida, että tutkijan omat mieltymykset, asenteet ja arvot ovat voineet vaikuttaa marginaalisesti tutkimukseen.

Tutkimus otti huomioon suhteellisen hyvin nimikkeiden kysyntään vaikuttavia tekijöitä ja toi esille aiemmista teorioista muodostettuja johtopäätöksiä. Tutkimuksessa on kuitenkin joitain aukkoja, jotka jättävät tutkimustulokset ilman lopullista varmistusta. Eräs tällainen on lopullinen ennustusprosessin testaus, jossa kokeellisen tutkimuksen kautta testattaisiin ennustusprosessin toimivuus osana kohdeyrityksen organisaatiota. Rajatun tutkimuksen aikavälin takia tällainen ennustusprosessin testaus ei ole mahdollinen. Toisaalta ennustusprosessin jatkokehittäminen ja optimoiminen eivät myöskään ole mahdollisia rajatussa ajassa.

## 5.4 Suositukset jatkotutkimukselle

Tutkimuksessa suoritettua kirjallisuuskatsauksen ja empiirisen osan perusteella pystytään toteamaan, että lisää tutkimusta ennustamiseen liittyy tarvitsemaan. Varsinkin projektimaisen liiketoiminnan kannalta tutkimus on erittäin puutteellista. Suurin osa aiemmista tutkimuksista keskittyvät joko tasaisesti tai epäsäännöllisesti kuluvien tuotteiden ennustamiseen kaupallisessa toiminnassa, jossa pyritään erilaisten mallien avulla vastaamaan varastonhallinnan tarpeisiin. Projektiliiketoiminnassa ominaista on tuotteiden hetkellinen tarve tietyissä projektin vaiheissa, mikä hankaloittaa kysynnän ennustamista.

Projektiliiketoiminnalle ja projekteille on myös yleisesti tyypillistä, että käytettävät materiaalit eroavat projekteissa. Jokainen projekti on erilainen monimutkainen kokonaisuus eri materiaaleja, mikä hankaloittaa varsinkin pitkän aikavälin ennustamista. Tämän takia ennustaminen projektiliiketoiminnassa on haastavaa, mutta tutkimisen arvoista. Projektit ovat myös erityisiä siitä syystä, että niillä on aina alku- ja loppuajankohta, mikä tuo oman ulottuvuutensa ennustamiseen. Projektiliiketoiminnan kannalta ennustamisessa projektiaikataulu ja suunnitelmat näyttelevät suurta roolia, kun taas jatkuvan liiketoiminnan ympäristöissä muut tekijät.

Yksittäisissä laajoissa projekteissa tarvittavien materiaalien tarpeiden ennustaminen perustuu pääsääntöisesti suunnitelmiin ja projektiaikatauluihin, joiden perusteella materiaaleja tilataan riittävän ajoissa ennen kulutusta. Tilanteissa, joissa organisaatio tekee

useampia toisiaan muistuttavia projekteja osittain tai pääsääntöisesti samoilla materiaaleilla, on mahdollista ennustamisessa hyödyntää aikaisempien projektien toteutuneita tarpeita. Tämänkaltaisen tarkastelu muuttaa merkittävästi materiaalien tarpeisiin varautumista. Lähtökohtaisesti jokainen projekti on yksilöllinen ja ainutkertainen kokonaisuus, tietyllä aikataululla, tietyillä materiaaleilla rakennettuna ja tietyillä tavoitteilla. Projektiliiketoiminnassa toisiaan muistuttavat projektit luovat kuitenkin mahdollisuuden historiaperusteiseen kysynnän varautumiseen ja ennustamiseen.

Merkittävä ero jatkuvan liiketoiminnan ja projektiliiketoiminnan välillä on materiaalien kulumisen joko tasaisesti tai tietyissä projektien vaiheissa. Tyypillistä projekteille on, ettei materiaaleja tarvita jatkuvasti, vaan kulutusta esiintyy epäsäännöllisesti tai vain tietyissä vaiheissa. Jos projektit muistuttavat riittävästi toisiaan voidaan tätä tarvetta ennakoida ilman tarkkaa suunnittelua materiaalin käytöstä. Usein yrityksillä on useampi projekti käynnissä samanaikaisesti, jolloin materiaaleja ostetaan useampiin projekteihin yhtä aikaa. Ennustamista on mahdollista helpottaa tarkastelemalla jokaista projektia erillään itsenäisenä kokonaisuutena, jolla on tietyt ominaisuudet ja tietty aikataulu.

Tasaisen liiketoiminnan osalta varastomateriaalien ennustaminen on huomattavasti yksinkertaisempaa verrattuna projektiliiketoimintaan. Tasaisen liiketoiminnan yrityksillä materiaalien kysyntä voidaan jaotella kahteen erilliseen ulottuvuuteen: ajoitukseen ja määrään. Projektiliiketoiminnassa materiaalien kysyntään liittyy vahvasti projektiulottuvuus, eli mihin projektiin materiaali tarvitaan. Ennustamista tutkimuksissa aiemmissa tutkimuksissa ei ole otettu huomioon tämän kaltaista kolmatta ulottuvuutta. Tässä tutkimuksessa huomioitiin projektiulottuvuus datan manipuloinnin kautta, mutta jatkotutkimuksen kannalta olisi oleellista huomioida projektiulottuvuus suoraan ennustusmalleissa.

Tässä tutkimuksessa huomioitiin projektiulottuvuus uusien nimikkeiden ennustamiseen kehitetyssä malli. Tämä malli vaatii myös jatkotutkimusta muiden projektiliiketoimintapausten osalta. Vaikka malli kohdeyrityksen tilanteeseen sopiikin, se pitäisi testata useamman yrityksen ja tilanteen kohdalla erikseen. Uusien nimikkeiden ennustaminen on ylipäättään haastavaa ja kehitetty malli tarjoaa projektiliiketoimintaan hyvän lähtökohdan uusien materiaalien kysynnän ennustamiselle.

# LÄHTEET

Armstrong, J.S. & Collopy, F. (1992). Error measures for generalizing about forecasting methods: Empirical comparisons, *International Journal of Forecasting*, Vol. 8(1), pp. 69-80.

Armstrong, J.S. (1985). *Long-range forecasting: From Crystal Ball to Computer*, 2nd ed. John Wiley & Sons, New York.

Barratt, M. & Oliveira, A. (2001). Exploring the experiences of collaborative planning initiatives, *International Journal of Physical Distribution and Logistics Management*, Vol. 31(4), pp. 266-289.

Bon, A.T. & Leng, C.Y. (2009). The fundamental on demand forecasting in inventory management, *Australian Journal of Basic and Applied Sciences*, Vol. 3(4), pp. 3937-3943.

Boulaksil, Y. & Franses, P.H. (2009). Experts' stated behavior, *Interfaces*, Vol. 39(2), pp. 168-171.

Boylan, J.E., Syntetos, A.A. & Karakostas, G.C. (2008). Classification for forecasting and stock control: A case study, *Journal of the Operational Research Society*, Vol. 59(4), pp. 473-481.

Caniato, F., Kalchschmidt, M. & Ronchi, S. (2011). Integrating quantitative and qualitative forecasting approaches: Organizational learning in an action research case, *Journal of the Operational Research Society*, Vol. 62(3), pp. 413-424.

Chatfield, C. (2000). *Time-series forecasting*, 1st ed. Chapman and Hall/CRC, Boca Raton.

Chen, F., Drezner, Z., Ryan, J.K. & Simchi-Levi, D. (2000). Quantifying the bullwhip effect in a simple supply chain: The impact of forecasting, lead times, and information, *Management science*, Vol. 46(3), pp. 436-443.

Croston, J.D. (1972). Forecasting and Stock Control for Intermittent Demands, *Operational Research Quarterly* (1970-1977), Vol. 23(3), pp. 289-303.

Danese, P. & Kalchschmidt, M. (2011). The role of the forecasting process in improving forecast accuracy and operational performance, *International Journal of Production Economics*, Vol. 131(1), pp. 204-214.

Davydenko, A. & Fildes, R. (2013). Measuring Forecasting Accuracy: The Case Of Judgmental Adjustments To Sku-Level Demand Forecasts, *International Journal of Forecasting*, Vol. 29(3), pp. 510-522.

Diebold, F.X. (1998). *Elements of forecasting*, University of Pennsylvania, Pennsylvania.

Eaves, A.H.C. & Kingsman, B.G. (2004). Forecasting for the ordering and stock-holding of spare parts, *Journal of the Operational Research Society*, Vol. 55(4), pp. 431-437.

European Union (2015). User guide to the SME definition, 1st ed. Luxembourg.

Evans, M.K. (2008). *Practical Business Forecasting*, 1st ed. John Wiley & Sons, 1-501 p.

Feigin, G. (2011). *Supply chain planning and analytics: the right product in the right place at the right time*, 1st ed. Business Expert Press, [New York, N.Y.] (222 East 46th Street, New York, NY 10017).

Fildes, R., Goodwin, P., Lawrence, M. & Nikolopoulos, K. (2009). Effective forecasting and judgmental adjustments: an empirical evaluation and strategies for improvement in supply-chain planning, *International Journal of Forecasting*, Vol. 25(1), pp. 3-23.

Fildes, R. & Petropoulos, F. (2015). Improving forecast quality in practice, *Foresight: The International Journal of Applied Forecasting*, Vol. 36 pp. 5-12.

Gardner Jr., E.S. (2006). Exponential smoothing: The state of the art-Part II, *International Journal of Forecasting*, Vol. 22(4), pp. 637-666.

Gelper, S., Fried, R. & Croux, C. (2010). Robust forecasting with exponential and holt-winters smoothing, *Journal of Forecasting*, Vol. 29(3), pp. 285-300.

Georgoff, D.M. & Murdick, R.G. (1986). Manager's guide to forecasting, *Harvard Business Review*, Vol. 64(1).

Goodwin, P. & Lawton, R. (1999). On the asymmetry of the symmetric MAPE, *International Journal of Forecasting*, Vol. 15(4), pp. 405-408.

Green, K.C. & Armstrong, J.S. (2015). Simple versus complex forecasting: The evidence, *Journal of Business Research*, Vol. 68(8), pp. 1678-1685.

Hanke, J.E., Reitsch, A.G. & Wichern, D.W. (2001). *Business forecasting*, Prentice Hall New Jersey.

Harris, M. (2014). *Inside the crystal ball: how to make and use forecasts*, Wiley, Hoboken, New Jersey.

Heinecke, G., Syntetos, A.A. & Wang, W. (2013). Forecasting-based SKU classification, *International Journal of Production Economics*, Vol. 143(2), pp. 455-462.

Hogarth, R.M. & Makridakis, S. (1981). Forecasting and planning: An evaluation, *Management science*, Vol. 27(2), pp. 115-138.

Holt, C.C. (2004). Forecasting seasonals and trends by exponentially weighted moving averages, *International Journal of Forecasting*, Vol. 20(1), pp. 5-10.

Hsu, C. & Sandford, B.A. (2007). The Delphi technique: making sense of consensus, *Practical assessment, research & evaluation*, Vol. 12(10), pp. 1-8.

- Hyndman, R.J. & Koehler, A.B. (2006). Another look at measures of forecast accuracy, *International Journal of Forecasting*, Vol. 22(4), pp. 679-688.
- Kalekar, P.S. (2004). Time series forecasting using holt-winters exponential smoothing, Kanwal Rekhi School of Information Technology.
- Kolassa, S. & Siemsen, E. (2014). Demand forecasting for managers, 1st ed. Business Expert Press, New York, New York (222 East 46th Street, New York, NY 10017).
- Lawrence, M., O'Connor, M. & Edmundson, B. (2000). Field study of sales forecasting accuracy and processes, *European Journal of Operational Research*, Vol. 122(1), pp. 151-160.
- Lim, J.S. & O'Connor, M. (1995). Judgemental adjustment of initial forecasts: Its effectiveness and biases, *Journal of Behavioral Decision Making*, Vol. 8(3), pp. 149-168.
- Makridakis, S. & Hibon, M. (2000). The M3-competition: Results, conclusions and implications, *International Journal of Forecasting*, Vol. 16(4), pp. 451-476.
- Mas-Machuca, M., Sainz, M. & Martinez-Costa, C. (2014). A review of forecasting models for new products, *Intangible Capital*, Vol. 10(1), pp. 1-25.
- Masini, E.B. & Vasquez, J.M. (2000). Scenarios as Seen from a Human and Social Perspective, *Technological Forecasting and Social Change*, Vol. 65(1), pp. 49-66.
- Mentzer, J.T., Moon, M.A., Estampe, D. & Margolis, G. (2007). Demand management, *Handbook of global supply chain management*, pp. 65-85.
- Montgomery, D.C., Jennings, C.L. & Kulahci, M. (2015). Introduction to time series analysis and forecasting, John Wiley & Sons.
- Moon, M.A., Mentzer, J.T. & Smith, C.D. (2003). Conducting a sales forecasting audit, *International Journal of Forecasting*, Vol. 19(1), pp. 5-25.
- Muckstadt, J.A. & Sapra, A. (2010). Principles of Inventory Management : When You Are Down to Four, Order More, Springer New York, New York.
- Müller, M. (2011). Essentials of inventory management, 2nd ed. AMACOM, New York.
- Norris, J.R. (1998). Markov chains, Cambridge university press.
- Prak, D. & Teunter, R. (2019). A general method for addressing forecasting uncertainty in inventory models, *International Journal of Forecasting*, Vol. 35(1), pp. 224-238.
- Rego, J.R.D. & Mesquita, M.A.D. (2015). Demand forecasting and inventory control: A simulation study on automotive spare parts, *International Journal of Production Economics*, Vol. 161 pp. 1-16.
- Rowe, G. & Wright, G. (1999). The Delphi technique as a forecasting tool: issues and analysis, *International Journal of Forecasting*, Vol. 15(4), pp. 353-375.
- Rowe, G. & Wright, G. (2001). Expert opinions in forecasting: the role of the Delphi technique, 1st ed. Springer, 1-144 p.

- Sanders, N.R. (2015). *Forecasting fundamentals*, 1st ed. Business Expert Press, New York.
- Saunders, M., Lewis, P. & Thornhill, A. (2016). *Research methods for business students*, Seventh ed. Pearson Education, New York.
- Schultz, C.R. (1987). Forecasting and inventory control for sporadic demand under periodic review, *Journal of the Operational Research Society*, Vol. 38(5), pp. 453-458.
- Seuring, S. & Müller, M. (2008). From a literature review to a conceptual framework for sustainable supply chain management, *Journal of Cleaner Production*, Vol. 16(15), pp. 1699-1710.
- Skulmoski, G.J., Hartman, F.T. & Krahn, J. (2007). The Delphi method for graduate research, *Journal of Information Technology Education: Research*, Vol. 6 pp. 1-21.
- Stank, T., Crum, M. & Arango, M. (1999). Benefits of interfirm coordination in food industry supply chains, *Journal of business logistics*, Vol. 20(2).
- Stevenson, W.J. (2014). *Operations management*, 12th ed. McGraw-Hill Education, Irwin, Boston.
- Syntetos, A.A. & Boylan, J.E. (2005). The accuracy of intermittent demand estimates, *International Journal of Forecasting*, Vol. 21(2), pp. 303-314.
- Syntetos, A.A. & Boylan, J.E. (2006). On the stock control performance of intermittent demand estimators, *International Journal of Production Economics*, Vol. 103(1), pp. 36-47.
- Syntetos, A.A., Boylan, J.E. & Croston, J.D. (2005). On the categorization of demand patterns, *Journal of the Operational Research Society*, Vol. 56(5), pp. 495-503.
- Teunter, R.H., Syntetos, A.A. & Babai, M.Z. (2011). Intermittent demand: Linking forecasting to inventory obsolescence, *European Journal of Operational Research*, Vol. 214(3), pp. 606-615.
- Van Der Heijden, K. (2000). Scenarios and forecasting: two perspectives, *Technological forecasting and social change*, Vol. 65(1), pp. 31-36.
- van Kampen, T.J., Akkerman, R. & van Donk, D.P. (2012). SKU classification: A literature review and conceptual framework, *International Journal of Operations and Production Management*, Vol. 32(7), pp. 850-876.
- Waddell, D. & Sohal, A.S. (1994). Forecasting: The Key to Managerial Decision Making, *Management Decision*, Vol. 32(1), pp. 41-49.
- Willemain, T.R., Smart, C.N. & Schwarz, H.F. (2004). A new approach to forecasting intermittent demand for service parts inventories, *International Journal of Forecasting*, Vol. 20(3), pp. 375-387.
- Williams, T.M. (1984). Stock control with sporadic and slow-moving demand, *Journal of the Operational Research Society*, Vol. 35(10), pp. 939-948.